RAY PUBLISHING & SCIENCE

الشبكات العصبونية بالتطبيقات العملية

ترجمة وإعداد
الدكتور المهندس نذير حسن الحرز

الشبكات العصبونية
بالتطبيقات العملية

- الطبعة الأولى 2008
- الناشر: شعاع للنشر والعلوم

حارة الرباط 2 - المنطقة 12 - حي السبيل 2
تلفاكس : 2643545 (21) 00963
هاتف : 2643546 (21) 00963
سورية ـ حلب
ص.ب 7875

لمزيد من المعلومات ولشراء كتب الدار مباشرة على الإنترنت

يرجى زيارة موقعنا http://www.raypub.com
البريد الإلكتروني للقراء: quality@raypub.com
info@raypub.com
البريد الإلكتروني للزبائن: sales@raypub.com
البريد الإلكتروني لدور النشر: orders@raypub.com

الشبكات العصبونية
بالتطبيقات العملية

ترجمة واعداد

الدكتور المهندس نذير حسن المحرز

الإهداء

إلى الذي على يديه تكسرت أمواج الزمن ليهيئ لنا بحراً ساكناً تبحر فيه مراكبنا... إلى والدي الغالي.

إلى التي أعرفها قبل أن أعرف الحياة... إلى ينبوع العطف والحنان... إلى أمي الحنونة.

إلى أعز الناس إلى قلبي... إلى من يشاركني أفراحي وأتراحي... إلى زوجتي الحبيبة.

إلى أزهار الربيع المتفتحة دوماً... إلى من يسري دمهم في عروقي... إلى أولادي الأعزاء.

إلى كل مهتم وباحث يتطلع إلى المعرفة ويبحث عنها ليسخرها في خدمة الإنسانية وبناء الوطن.

نذير

مقدمة

تطورت التقانات الحاسوبية الذكية الجديدة لتقدم حلولاً عديدةً لمعضلات كثيرة في مجالات مختلفة كالطب، والاقتصاد، والهندسة، والفيزياء. وتشترك هذه التقانات بصفة عامة، وهي أنها قد تم استيحاؤها من النظم البيولوجية الإنسانية الطبيعية. فهي تعتمد على بناء نظم قادرة على محاكاة عمليات التفكير، والادراك، والاستنتاج المنطقي، التي يجيدها الإنسان دون تعليم، ويؤديها بشكلٍ تلقائي دون أدنى تفكير. يستقبل الدماغ الإنساني البيانات الخارجية عن طريق الحواس، فيتم تخزين هذه البيانات بشكلٍ مؤقت في الذاكرة الاحتياطية، ليتم نقلها إلى الذاكرة طويلة الأمد التي تحلل وتخزن جميع الأشكال والرموز والخبرات والتجارب التي اكتسبها الإنسان طيلة حياته.

وتمثل الشبكات العصبونية الصنعية، والنظم الخبيرة، والأنظمة المبنية على منطق الغموض، والخوارزميات الوراثية، أحد الأمثلة الجذابة لهذه التقانات الحاسوبية الذكية، التي أدت بمجموعها إلى ظهور علم الذكاء الصنعي، الذي يعتبر أحد فروع علم الحاسوب الذي يسعى لفهم ومحاكاة القدرات العقلية للإنسان عن طريق كتابة برمجيات وتنفيذها وملاحظة سلوكها وتعديلها.

تعتبر الشبكات العصبونية الصنعية إحدى تقانات الذكاء الصنعي انبثقت من الدماغ والجهاز العصبي للإنسان، حيث تم استخدامها في كثير من التطبيقات باستخدام الحاسوب كالتعرف على النماذج والأشكال والأصوات. ويعتمد نجاح هذه التطبيقات على الاختيار المناسب لبنية الشبكة العصبونية الصنعية، وبارامتراتها، وخوارزمية التعلم المطبقة، والتوابع الرياضية المستخدمة في حساب فعالياتها عصبوناتها. مما أدى إلى وجود عددٍ كبير من أنواع الشبكات العصبونية الصنعية بالإضافة إلى خوارزميات تعليم مختلفة.

يحاول هذا الكتاب عرض وجهة نظر أكثر الأعمال حداثةً في مجال الذكاء الصنعي الاتصالي. ولاتشمل هذه الأعمال فقط على تطورات نظرية للنماذج الجديدة للعناصر الجوهرية من الأنظمة الاتصالية، وإنما على تطبيقات تلك الانظمة باستخدام الخصائص الذكية من أجل تحقيق التكيّفية، والتعلم الذاتي، والتصنيف، والتنبؤ، وحتى الخلق والابداع الفني.

هذا الكتاب مُقسم إلى ستة أقسام، ومؤلف من 16 فصلاً. يقدم القسم الأول التقدمات الحديثة في دراسة العصبونات البيولوجية، ويبين كيف يمكن أن تُستخدم تلك التقدمات من أجل تطوير نماذج حسابية جديدة للشبكات العصبونية الصنعية. حيث يظهر الفصل الأول دراسة تدمج عناصر تحاكي خلايا النظام الدبقي مع الأنظمة الاتصالية. وتُعرّف الأنظمة الاتصالية المقترحة

بالشبكات العصبونية الدبقة الصنعية. بينما يوسّع الفصل الثاني الشبكات العصبونية الصنعية إلى الشبكات العصبونية الدبقة الصنعية، التي تُعتبر فيها خلايا الدبق.

إن التقنيات الجديدة – كالتقنيات الاتصالية – مُفضلة في حالات مثل تحليل السلاسل الزمنية، الذي كان مجالاً للبحث والاستقصاء النشيط في الاحصاء لفترة طويلة. بَيْدَ أنه لم تُحقق النتائج المتوقعة في مناسبات عديدة. يعرض القسم الثاني تطبيق الشبكات العصبونية للتنبؤ بالسلاسل الزمنية. في حين يقدم الفصل الثالث حوسبة تطورية هجينة مع توليفة لشبكة عصبونية صنعية من أجل التنبؤ بالسلاسل الزمنية. وقُيّمت هذه الاستراتيجية بـ 10 سلاسل زمنية، وقُرنت بالطرق الأخرى. أما الفصل الرابع، فيعرض استخدام الشبكات العصبونية الصنعية والتقنيات التطورية من أجل التنبؤ بالسلاسل الزمنية مع منظومة متعددة المستويات لضبط البنية الهندسية للشبكات العصبونية الصنعية.

في عالم قواعد البيانات، كان اكتشاف المعرفة (وهي تقنية تعرف بالتنقيب عن البيانات) أداة مفيدة جداً للعديد من الأغراض المختلفة. يصف القسم الثالث استراتيجيات معتمدة على الشبكات العصبونية الصنعية للبحث عن المعرفة واستخلاصها من البيانات المخزنة. إذ يصف الفصل الخامس تقنيات تطورية معتمدة على الخوارزمية الوراثية من أجل بناء أنظمة عصبونية ذكية آلياً. يُطبق هذا النظام في الاختبارات المخبرية والمسائل الواقعية: كتشخيص سرطان الثدي. ويظهر الفصل السادس تقنية تقوم باستخلاص المعرفة المُحتفظ بها من قبل شبكات عصبونية صنعية مدربة مسبقاً، وقد تم التركيز على الشبكات العصبونية التكرارية بشكل خاص. أما الفصل السابع، فيشرح عدة طرق بغية تحديد ماهي المجموعة الجزئية من المتغيرات، التي يجب أن تكون ذات الصلة الأكثر، من أجل الأداء لمهمة تصنيف. يُطبق الحل المقترح ويُختبر على حالة عملية في مجال الكيمياء التحليلية (تصنيف مشروبات التفاح).

مازال التقدم في حقل الذكاء الصنعي يبدي تأثيراً قوياً على مجال الهندسة المدنية، حيث تنبثق طرق وخوارزميات جديدة، تمكن المهندسين المدنيين من استخدام الحاسبات في نواحي مختلفة. يبين القسم الرابع تطبيقين للشبكات العصبونية الصنعية على هذا المجال. يعود التطبيق الأول إلى المجال الهيدروليجي، أما الثاني فيشير إلى مجال البناء. يصف الفصل الثامن تطبيق الشبكات العصبونية الصنعية والحوسبة التطورية من أجل نمذجة تأثير المطر على الجريان السطحي في حوض صرف مدنية نموذجي. ويقدم الفصل التاسع تنبؤ تماسكية الخرسانة باستخدام الشبكات العصبونية الصنعية.

من الواضح أن التطبيقات في المجال الاقتصادي، وتحديداً من أجل مهام التوقع هامة تماماً، طالما أن التحليل المالي هو أحد مجالات البحث، حيث تُطبق بشكل مستمر تقنيات جديدة

كالمنظومات الاتصالية. يعرض القسم الخامس تطبيقين للشبكات العصبونية الصنعية لتوقع المهام في هذا المجال. أحدهما من أجل توقع تخمين الصكوك، والآخر من أجل توقع تخمينات الائتمان: فيعرض الفصل العاشر تطبيق تقنيات الحساب الناعم على مسألة عالية البُعدية: وهي توقع تخمين الصكوك. تُطبق تقنية تخفيض البُعدية، وتقنية تخفيض المتغير، والشبكات الهجينة، وتقنية المنطق العائم العادي، والشبكات العصبونية الصنعية بغية حل هذه المسألة. ويعطي الفصل الحادي عشر مثالاً على كيفية أتمتة عناصر مهمة بناء الشبكة العصبونية الصنعية بواسطة خوارزمية تطورية، أثناء توقع تخمينات الائتمان.

أخيراً، يعرض القسم السادس تطبيقات متعددة للشبكات العصبونية الصنعية في مجالات حديثة جداً، مظهراً اهتمام الباحثين المختلفين بها. يقدم هذا القسم تطبيقات من أجل خلق وتأليف الموسيقي (الفصل 14)، وتقنيات كشف التدخل (الفصل 15)، والتطبيقات الفلكية لصور النجوم (الفصل 16). حيث يشرح الفصل الثاني عشر العلاقة المُعقدة بين الموسيقى والشبكات العصبونية الصنعية مركزاً على مواضيع هامة كالتأليف الموسيقي أو تمثيل اللغة الموسيقية. ويشرح الفصل الثالث عشر اساسات نظام دعم جديد لمصيدات السمك يعتمد على التقنيات الاتصالية، ومعالجة الصور الرقمية، والمنطق العائم. أما الفصل الرابع عشر، فيقترح نموذج شبكة عصبونية صنعية للحصول على استراتيجية تحكم. يتوقع لهذه الاستراتيجية أن تكون قابلة للتطبيق على تخمين الكلفة وطرق المحاسبة. ويقدم الفصل الخامس عشر طريقة هجينة جديدة لتكامل نظرية المجموعات الخشنة، والخوارزمية الوراثية، والشبكات العصبونية الصنعية. والهدف من ذلك، هو تطوير نظام كشف التدخل. وأخيراً، يصف الفصل السادس عشر طريقة هجينة لتصنيف غير موجود لأطياف النجوم الضوئية منخفضة التمييز بواسطة تكامل عدة تقنيات ذكاء صنعي.

بعد كل ماذكر، يمكن اعتبار هذا الكتاب مصدراً غنياً بالمعلومات والمقترحات العلمية الحديثة جداً، التي ستساهم في حل مشاكل الأنظمة القديمة المعتمدة على المعرفة، كما ستساهم في فتح أسلوب جديد يمكنه بلا شك تحقيق تقدم في هذا المجال.

وفي النهاية، أتوجه بالشكر والامتنان لكل من ساهم في إخراج هذا الكتاب، وجعله مرجعاً مفيداً في المكتبة العربية، وأخص بالشكر الدار الناشرة – شعاع – والعاملين فيها لما بذلوه من جهد.

الدكتور المهندس نذير حسن المحرز

2008/2/11

القسم 1

التعديل البيولوجي (الحيوي)

الفصل الأول

سلوك الدبق العصبي في علم الحاسوب

ملخص

يقدم هذا الفصل دراسة تدمج مع الأنظمة الربطية عناصر جديدة تحاكي خلايا نظام الدبق العصبي. حيث دُرست صنف محدد من خلايا الدبق العصبي المعروفة بالخلايا النجمية (Astrocytes) والتي يُعتقد أنها تدخل بشكل مباشر في معالجة الدماغ للمعلومات. لقد ساعدت النماذج الحسابية على تقديم فهم أفضل للأسباب والعوامل المتضمنة في الأداء الوظيفي المعين لدارات دماغية خاصة. ستستخدم الدراسة المقدمة وجهات النظر الجديدة هذه للتقدم في مجال العلوم الحاسوبية والذكاء الصنعي. تدعى الأنظمة الربطية المقترحة بشبكات الدبق العصبوني الصنعي (ANGN) Artificial Neuroglial Networks

مقدمة

يبين تحليل النماذج الحسابية المُطورة حتى الآن أن الشبكات العصبونية الصنعية (ANN) تمتلك حدوداً معينة كمخططات لمعالجة المعلومات. ونحن نعتقد بأن هذه الحدود أو القيود يمكن أن تكون ناجمة عن حقيقة أن النماذج الموجودة لا تعكس الأداء أو السلوك الأكيد للخلايا العصبية (العصبونات)، ولا تدرس مشاركة عناصر ليست هي بخلايا عصبونية صنعية. بما أن ANN تدعي بأنها تنافس الدماغ البشري، فقد حاولت الأبحاث أن تبرز الأهمية التي تمتلكها الخلايا العصبية في الجهاز العصبي، وبالتالي أحرزت خلال العقود الأخيرة تقدماً كبيراً في مجال علم الأعصاب، يبرز بشكل هائل في الدارات العصبية المعقدة كالنظام الدبقي glial system (GS) الذي درس بدقة. لقد قادت أهمية وظائف الـــ GS الباحثين إلى الاعتقاد بأن مشاركتها في معالجة المعلومات في الجهاز العصبي أكبر بكثير مما كان يعتقد سابقاً.

في هذه الحالة، قد يكون من المفيد تجميع العناصر الأخرى التي ليست خلايا عصبونية في نماذج صنعية. هذه العناصر المساعدة والتي لم تُدرس حتى الآن في النماذج الصنعية ستعمل على إنجاز

وظائف محددة كتسريع النقل النبضي، وتأسيس قواعد النقل الأفضل، واختيار العناصر المكونة لدارة معينة، واجراء المعالجة التجريبية للمعلومات (تحذير الدارات الأخرى ألا تتدخل في معالجة بعض المعلومات) ... وهلم جراً.

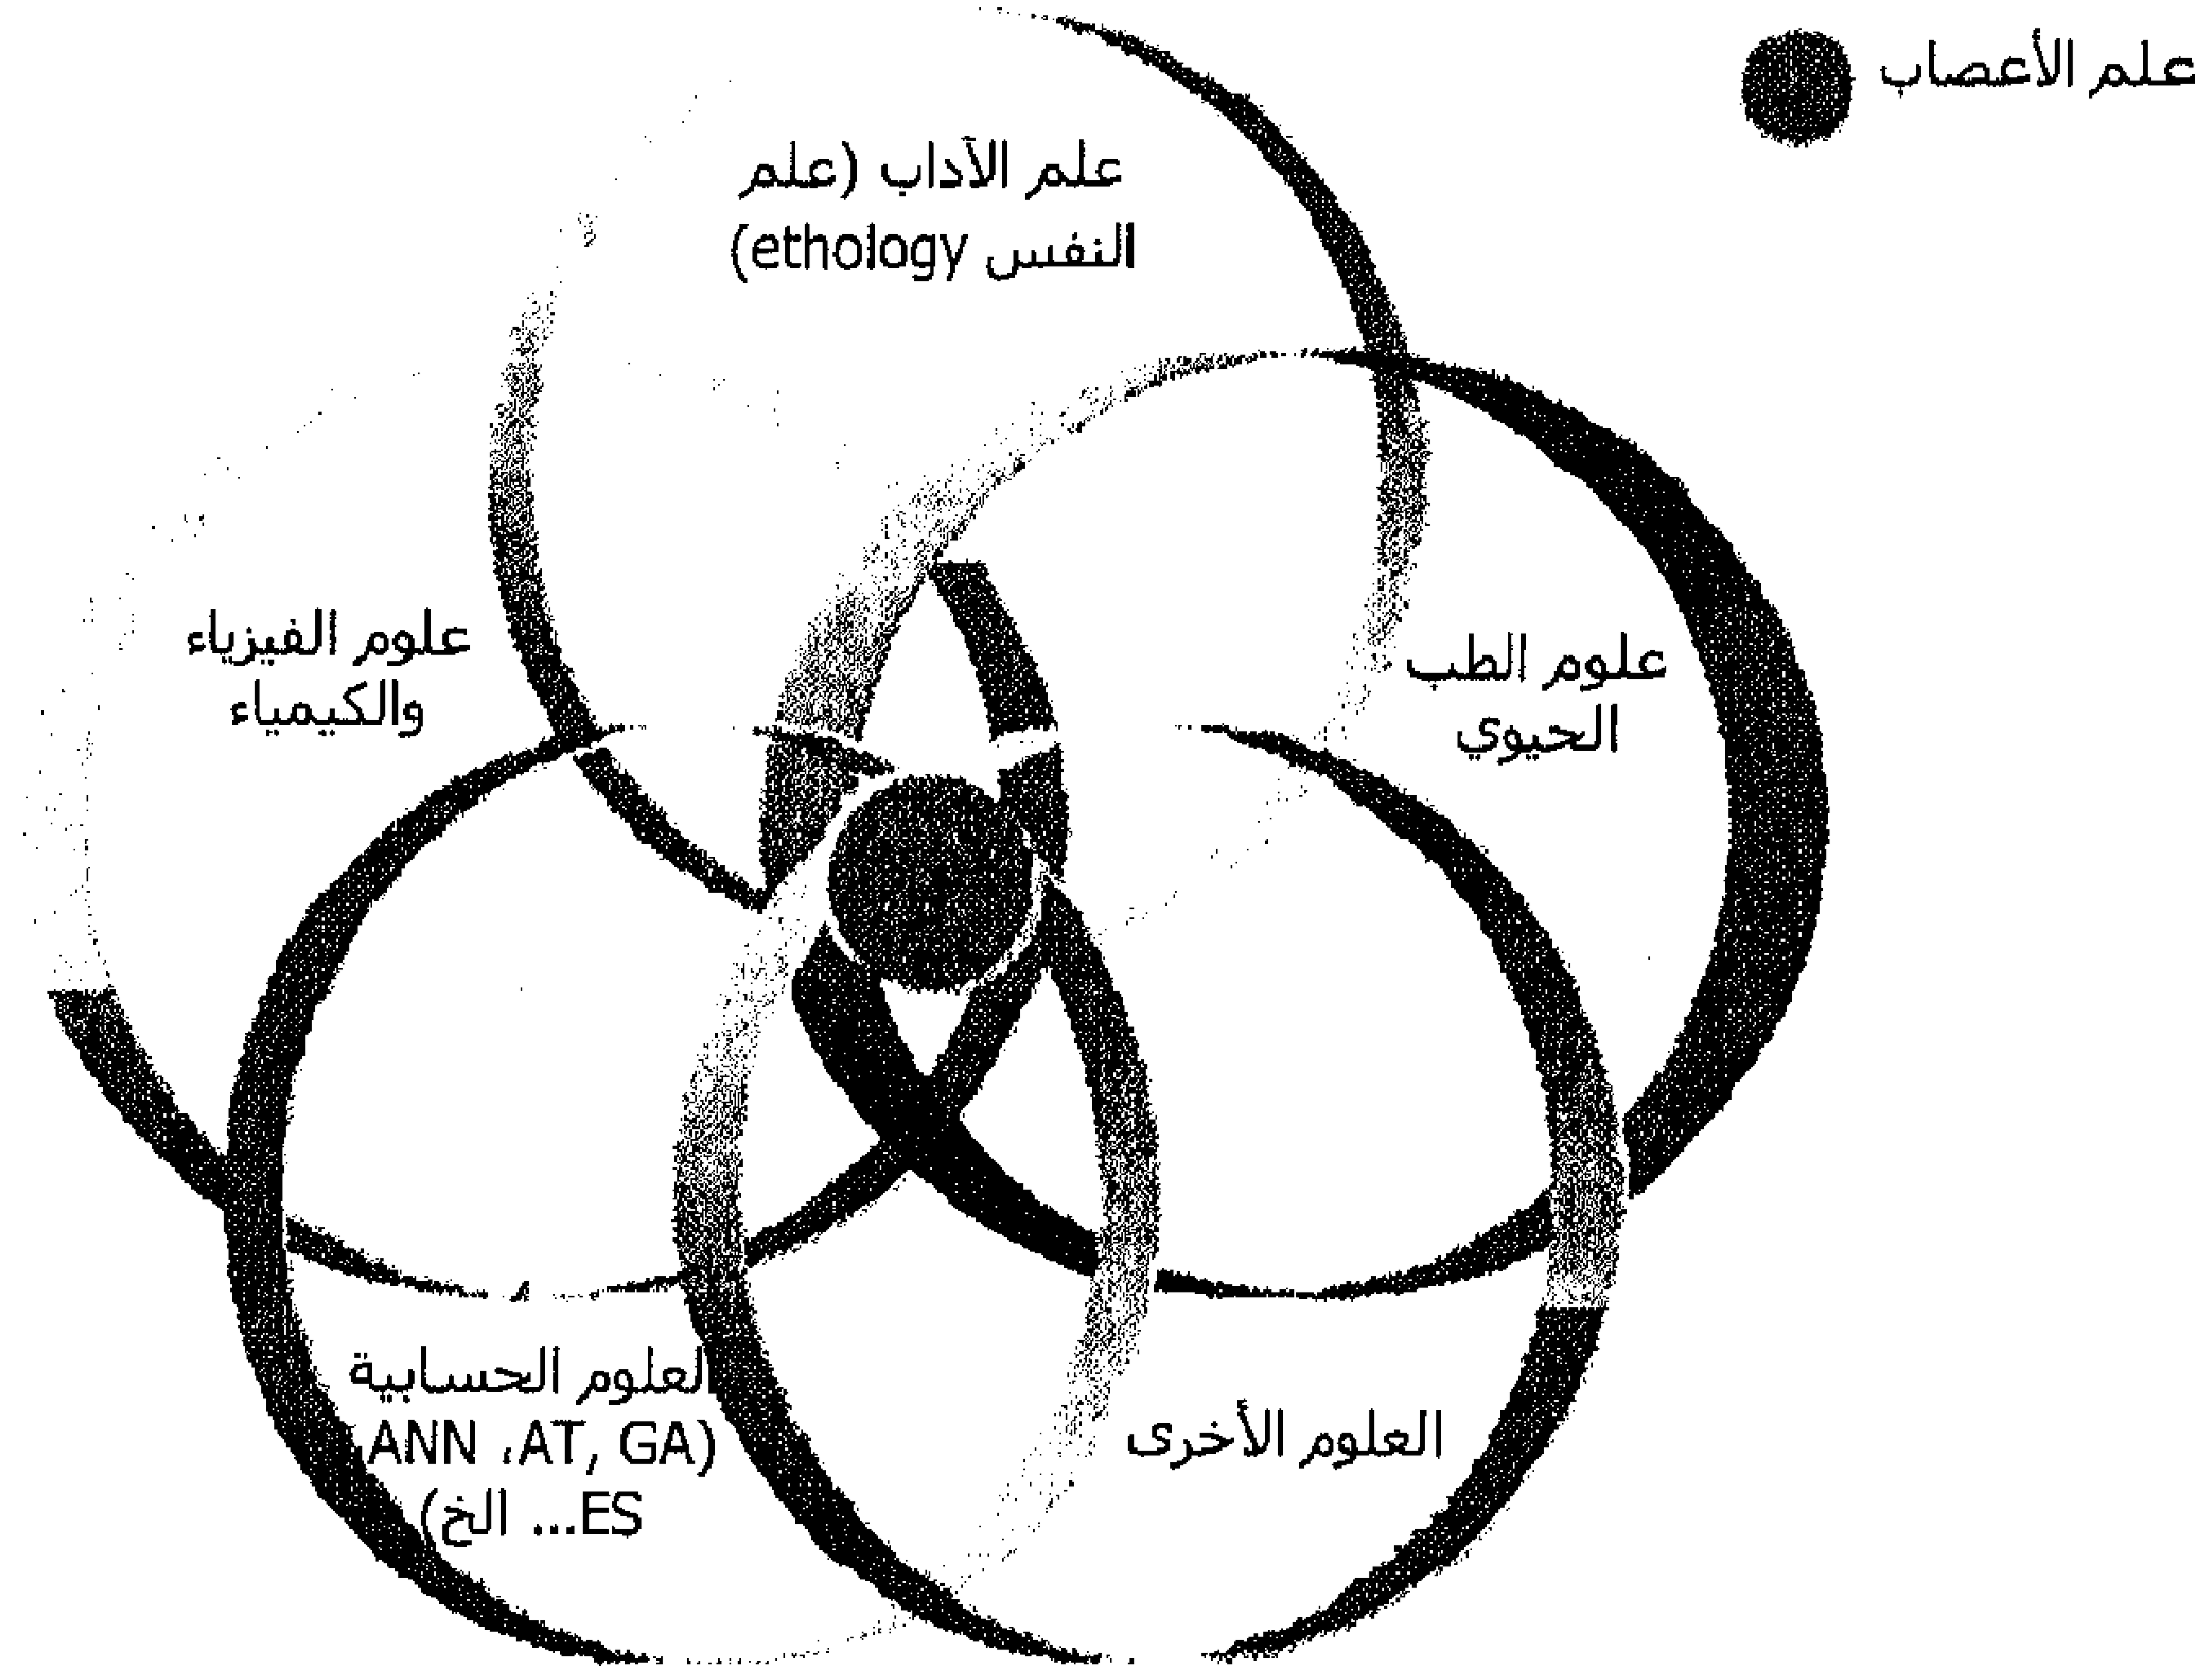
علم الأعصاب والأنظمة الربطية

من أجل تكوين ANN تنافس الدماغ البشري وإمكانياته الهائلة، يجب علينا أن نعرف بنيتهُ ووظائفه أن أن نفهمها جيداً. لكن لسوء الحظ فبالرغم من الاكتشافات الهائلة التي تمت خلال العقود الأخيرة كما ما زال الجهاز العصبي سراً غامضاً كما تنبأ العالم Cajal (1904) منذ قرن مضى.

لقد قادت دراسات كثيرة في مجالات المعرفة الاختصاصية إلى الجهاز العصبي. ففي البيولوجيا مثلاً (علم الأحياء) يمكننا دراسة أشكال مختلفة لحياة الحيوانات وتنوعاتها المدهشة بدون إدراك أن جميع هذه الأشكال تتعلق بالاختلاف والتباين الموافق في الجهاز العصبي. إن دراسة النماذج السلوكية للحيوانات في بيئتها الطبيعية التي أجريت لأول مرة من قبل الباحث الأكثر شهرةً Lorenz (1966) والذي حدد فئات النماذج السلوكية التي يمكن غرسها في الحواسيب تُعرف بالايثولوجيا (ethology). أما ترابط هذه النماذج والآلية العصبية فتدعى بـ neuroethology. وهكذا فإن دراسة السلوك البيولوجي من وجهة نظر حسابية يمكن أن تدعى بـ "Computational neuroethology" أو بـ "Computoneuroethology"، وفي علم النفس العام تبين الدراسات ذات الصلة من وجهة علم الأعصاب الحسابي العديد من الأسئلة حول الآليات الموجودة في الدماغ التي تحدد السلوك والقدرات البشرية.حديثاً نظم علماء الأعصاب (الجهاز العصبي) صفوفاً واسعة من التقنيات الجديدة والمنهجيات التي نشرت في مجالات علم الأحياء الخلوي والجزيئي وعلم الوراثة. وقد ساهمت مجالات البحث تلك إلى حد كبير في فهم النظام العصبي والآليات الخلوية والجزيئية والوراثية التي تتحكم وتدير الخلايا العصبية، كما أنها تشكل الخطوة الأولى باتجاه معالجة وتخزين معلومات الجهاز العصبي.

من المعروف عموماً بأن مجالات عديدة لعملية التعلّم تقتضي استخدام الجهاز العصبي، وبالتالي يمكن النظر إلى علم الأعصاب على أنه تقاطع بمجالات الاهتمام المتراكبة، وهو مجال جديد نسبياً، يعكس حقيقة مفادها – حتى الآن – أن العديد من العناوين المكونة له لم تُدرس بشكل كاف لتكون متقاطعة بطريقة هامة وذات معنى: علوم الآداب (علم النفس، ايثولوجي، ... الخ)، علومٌ الفيزياء والكيمياء، علوم الطب الحيوي، الذكاء الصنعي، والعلوم الحسابية.

الشكل 1. المجالات العلمية التي تساهم في علم الأعصاب.



في علم الأعصاب تقتضي دراسة الجهاز العصبي في الحيوانات الفقارية بشكل متزايد احتساب عناصر متنوعة ووجهات نظر مختلفة. حتى عقود مضت ركزت هذه الدراسات بشكل أساسي على تحليل الخلايا العصبية، ولكن بدأ الآن الاهتمام بدراسة أنواع أخرى من الخلايا ذات الصلة بخلايا الدبق، وبالتالي أصبح واضحاً بأن التركيز يجب أن يوّسع وأن يُجدّد اتجاه البحث.

الخلايا النجمية: وظائف في معالجة المعلومات

منذ أواخر الثمانيات فإن تطبيق التقنيات الفزيولوجية والخلوية المتكررة والمطورة باعتناء (مثل قامطة التوصل المؤقت، الصور الفلورية المحسوبة شاردياً، المجهر متحد المحرق، علم الأحياء الجزئي) على دراسات الدبق تحدى الفكرة الكلاسيكية التي تقول بأن الخلايا النجمية تزود الخلايا العصبية بالدعم البنيوي والغذائي فقط، وافترض أن هذه العناصر تلعب دوراً أكثر فعالية في فزيولوجية الجهاز العصبي المركزي (CNS).

كشفت الدراسات الحديثة النقاب عن اكتشاف مفاده أن الدبق يتصل بشكل وثيق بالتحكم الفعّال للنشاط العصبي ويأخذ حيزاً في تنظيم النقل العصبي المشبكي. نحن نعلم بأن الخلايا النجمية تمتلك وظائف استقلابية وبنيوية ووظائف استقرار داخلي مهمة جداً، وأنها تلعب دوراً هاماً وضرورياً في تطوير وفي فزيولوجية CNS، المتضمنة كما هي في هيئات أو سمات مفتاحية للوظيفة

العصبية كالدعم الغذائي (Cajal, 1911) والبقاء العصبي والتفاضل (Rall et. at. 1993)، التوجيه العصبي (Kuwada, 1986, Rakic, 1990)، والنمو الخارجي للعصبات (LeRoux & Reh, 1994) والفعالية المشبكية (Mauch et. al. 2001; Prieger & Barrss 1997). كما تساهم الخلايا النجمية أيضاً في توازن الدماغ بتنظيم تجمعات الأيونات المحلية (Largo, Cuevas, Somjen, Martin del Rio, & Herreas, 1996)، ومواد الفعالية العصبية (Mennericr & Zorunski, 1994). سوف نشرح بعض هذه السمات بشكل مختصر فيما بعد، بَيْدَ أنه يمكننا أن نؤكد الآن بأنها هامة جداً من وجهة نظر الأنظمة الاتصالية (CS)، لأنها تؤثر بشكل مباشر على الطبولوجية (والتي هي دراسة الخصائص الهندسية التي لا تتأثر بتغيير الحجم والشكل) وعلى عدد وخاصية عناصرها وطبقاتها.

لقد أظهر العالمان Rackic وKimelberg بأن الخلايا العصبية تهاجر عادةً من مكان إلى آخر بواسطة نوع ما من السقالة أو بطريق آمن مرتبطة بإطالات خلايا الدبق غير الناضجة التي ستختفي فيما بعد وتتحول إلى الخلايا النجمية. (Rackic, 1978; Kimelberg 1983). يجب بالتالي أن تُكمل الوظائف التقليدية للدعم العصبي والصيانة والعزل التي تُنسب عادة إلى الدبق بوظائف النمو "دليل" والتجديد المحتمل للخلايا العصبية. كما تعتني الخلايا النجمية بتسمم منتجات الأيض (الاستقلاب) المخية التي تحتوي على تركيز عالي للأنزيمات المركبة لمادة الدبق والاهدريد الكربوني وعناصر الـــ ATP المعتمدة على البوتاسيوم التي تساهم في الحفاظ على توازن ضيق للامونيا (غاز النشادر) والهيدروجين -CO2 والبوتاسيوم في الوسط المخي خارج الخلية.

تنفذ أيضاً الخلايا النجمية مهام فعالة ونشيطة في فسيولوجية المخ. وهي تلعب دوراً حاسماً في استقلاب (ايض) النواقل العصبية لحمض كلوماتات glutamate وحامض غاما الزبدي الأميني (GABA) والذين - بالمناسبة - يُمسكا من قبل الخلايا النجمية للفالق المشبكي والمُستقلب (المؤيض) لتشكيل مادة الدبق والحامض الأميني، اللذان يساعدان لاحقاً في تركيب نواقل عصبية جديدة. بين العلماء Norenbergs وHertz وSchousboe (1988) بأن الأنزيم المسؤول عن تركيب مادة الدبق موجود بشكل خاص في الخلايا النجمية المسؤولة عن الوجود الكافي للعنصر الذي يعتبر عاملاً حاسماً لنقل المعلومات بين الخلايا العصبية.

من جهة أخرى فإن الخلايا النجمية هي الخلايا التي يمكن أن تجمّع فيها مورثات الدبق كخزان ومنبع لمركبات الدبق بحيث تستخدم عند الحاجة. يُحرض إطلاق الغلوكوز من قبل نواقل عصبية مختلفة كالمواد التي يمتلك من أجلها غشاء الخلايا النجمية مستقبلات لم تُفهم حتى الآن آليتها الداخلية. وهي تحافظ أيضاً على التوازن التناضحي للدماغ بالرد في حالة الاعتداءات الايضية مثل الـــ ischemia بالزيادة السريعة بالحجم أو في حالة الاعتداءات الايضية مثل ischemia بالزيادة السريعة بالحجم أو بزيادة حجم المتقدرات (mitochondria) (Smith-Their- 1973).

عندما يتضرر الجهاز العصبي يمكن أن ترمم الخلايا النجمية وتنقى سوية مع خلايا الدبق الميكروية، وتقاد إلى هذا التأثير بسلسلة من التحويلات التشكيلية والوظيفية، وتكتسب كميات متكاثرة، وتصبح خلايا نجمية تفاعلية تشكل ندبة دبقية حول المنطقة المصابة تعزلها عن بقية النسيج العصبي، ليصلح بموجب ذلك المعالجة المعلوماتية بين الخلايا العصبية.

الوظيفة الهامة الأخرى للخلايا النجمية هي الموازنة المكانية للبوتاسيوم. كشف العالم Kuffler وفريق بحثه بأن الخلايا النجمية تزيل الزيادة في البوتاسيوم المولدة بالنشاط العصبي في الوسط خارج الخلية.

بوجود هذا التنوع في الوظائف ليس من المفاجئ أن تسبب التغيرات في الخلايا النجمية عدداً كبيراً من الأمراض في الجهاز العصبي. في بعض التغيرات المنطقية العصبية هناك ظواهر شاذة واضحة في الخلايا النجمية، بينما في بعض الحالات الأخرى تسبق هذه الظواهر الشاذة مثيلاتها في الخلايا العصبية. والأمثلة المشهورة على ذلك هي الصرع وتصلب الأنسجة المتعدد وبعض التغيرات النفسية (Kimelberg, 1989).

في حين أنه حتى زمن قريب جداً اكتشفت خلايا سلالية فقط في النخاع الشوكي، وفي الحبل السري وفي النسيج الجيني، فقد اكتشف العلماء Sanai، Tramontin، Quiñones، Barbaro وGupta عام 2004 وجود الخلايا السلالية في دماغ الإنسان البالغ (Sana et at. 2004). وحددوا موقع عصبة الخلايا السلالية التي يمكنأن تُستعمل بشكل فعال لتجديد نسيج الدماغ المتضرر وسلطوا ضوءاً جديداً على النوع الأكثر شيوعاً من الورم الدماغي. وقد كشفوا داخل التجويف الدماغي المملوء بسوائل الدماغ في المنطقة البطنية الفرعية طبقة من الخلايا النجمية - مزروعة في أنبوبة اختبار - التي يمكن أن تحول نفسها إلى خلايا عصبية، الأمر الذي يعني بأنه يمكن أن تجدد الخلايا النجمية نفسها، وتُنتج أنواع مختلفة من الخلايا الدماغية. وبالرغم من قدرة الأحياء على تجديد الخلايا العصبية، تبين الدراسة بوضوح أن لديهم قدرة كبيرة على ذلك، إذ يجب أن تحلّل بشكل أكثر عمقاً، ليتم فك شيفرة آليات التحكم بها.

كما كُشف أيضاً العديد من المستقبلات والمراسيل الثانوية في الخلايا النجمية. وتشير بعض الدراسات بأنه توجد مرسلات لمختلف النواقل العصبية، بالرغم من أن وظيفة هذه المستقبلات غير واضحة تماماً، فإن وجودها يقودنا للاعتقاد بأن الخلايا النجمية تستجيب للظروف المتغيرة للدماغ مع تعددية الاستعمال التي قد تكون مشابهة للخلايا العصبية وحتى أفضل منها.

الاتصال بين الخلايا النجمية، والخلايا العصبة: مفهوم جديد للمشبك

تحرر الخلايا النجمية النواقل الكيميائية وبشكل خاص أكثر - الزيادة في الكالسيوم التي تحدث داخلها عندما يتم تحريضها (Verchratsky, Orkand, & Kettenmann, 1998)، وتؤدي إلى تحرير

وحمض أميني (كلوماتات) أكثر النواقل العصبية الاستثارية للدماغ الموجودة بوفرة. لم تُعرف إلى الآن وظائف تحرير نواقل الدبق الكيماوية،ولكن من الواضح بأن التحفيز الذي يرفع نسبة الكالسيوم في الخلايا النجمية يدل على نشاط هذه الخلايا، ويحرر حمضاً أمينياً (كلوماتات). يمكن أن يؤدي تحرير الدبق هذا إلى تعديل النقل في المشابك المحلية (Haydon & Araque, 2002) التي دُرست بالفعل في البحث الحالي، حيث أننا حاولنا تعديل المشابك الحاصلة بين الخلايا العصبونية الصنعية لشبكة ما من خلال وجود وأداء عناصر تمثل الخلايا النجمية في تلك الشبكة.

اُقترحت في السنوات الأخيرة شواهد كثيرة على وجود اتصال ثنائي الاتجاه بين الخلايا النجمية والخلايا العصبية، وعلى الدور الفعال والهام للخلايا النجمية في فسيولوجية الجهاز العصبي. (Araque, Carmignoto, & Haydon, 2001; Perca & Araque, 2002). أدت هذه الشواهد إلى اقتراح مفهوم جديد في فسيولوجية المشبك الذي هو المشبك الثلاثي، الذي يتألف من ثلاثة عناصر وظيفية: عناصر قبل مشبكية، وعناصر بعد مشبكية والخلايا النجمية المحيطة (Araque, Purpura, Sanzgiti, & Haydon, 1999). يوجد لدى الاتصال بين هذه العناصر الثلاثة خصائص عالية التعقيد، تعكس بوثوقية أكثر تعقيداً معالجة المعلومات بين عناصر الجهاز العصبي (Martin & Araqua, 2005). وبالتالي لا يوجد شك حول وجود الاتصال بين الخلايا النجمية والخلايا العصبية (Percai & Araque, 2002). من أجل فهم دوافع هذه الإشارة المتبادلة يجب علينا أن نعرف الاختلافات والتشابهات الموجودة بين خصائصها. منذ عدة عقود مضت كان من السخيف الادعاء أن لهذين النوعين من الخلايا وظائف متماثلة جداً، أما الآن فنحن ندرك بأن هذه التشابهات تناقش من منظور الإشارة الكيمياوية. يستقبل كل من هذين النوعين من الخلايا الإدخالات الكيمياوية التي لها تأثير على المستقبلات ذات الوجود الأيوني المعتدل وذات الأيض المعتدل. يلي هذا التجميع إرسال كلا النوعين إشارات إلى جيرانهما من خلال تحرير النواقل الكيمياوية. تُظهر الإشارة الصادرة من خلية عصبية إلى خلية عصبية ومن خلية عصبية إلى خلية نجمية خصائص مرونة تعتمد على التنشيط والفعالية (Pastl, Volterra, Pozzan, Camignoto, 1997). ويكمن الفرق الرئيس بين الخلايا العصبية والخلايا النجمية في أن العديد من الخلايا العصبية تمد محاورها لمسافات كبيرة، وتوصل كمونات الفعل لمدة قصيرة بسرعة عالية، بينما لا تظهر الخلايا النجمية أي إشارة كهربائية، ولكنها توصل شوكات الكالسيوم لمدة طويلة (عشرات الثواني) لمسافات قصيرة وبسرعة منخفضة أو بطيئة. تُظهر الإشارات السريعة ووظائف الدخل والخرج في الجهاز العصبي المركزي الذي يتطلب السرعة، بأنها تنتمي للوسط العصبي. لكن ما الذي يحدث مع الأحداث الأبطأ مثل تحفيز الذكريات والعمليات التجريدية الأخرى كعمليات التفكير؟ هل تساهم الإشارات بين الخلايا النجمية بالتحكم بها؟ طالما أنه لا توجد إجابة على هذه الأسئلة فيجب مواصلة البحث. يعرض العمل الحالي طرقاً جديدة للتقدم من خلال استخدام تقنيات الذكاء الصنعي.

نعلم الآن بأن الخلايا النجمية بارزة جداً في النوع (الصنف) الأكثر تقدماً من الكائنات الحية. يبين (الجدول 1) مقارنة الملف الجيني المطورة من قبل العالم Haydon (2001). فمن أجل النوع الأخفض على مقياس الملف الجيني الذي يبقى مثالياً مع كمية صغرى من خلايا الدبق، فإن تبادل الإشارة بين الدبق والخلايا العصبية لا يبدو مهماً جداً.

الجدول (1) مقارنة الملف الجيني لخلايا الدبق في أنواع مختلفة للكائنات الحية.

النوع	نسبة خلية عصبية: خلية دبق
الحبليات (طائفة من الديدان الخيطية)	< 1
القوارض	1 : 1
دماغ الإنسان	~ 50 : 1

على أية حال يزيد التنشيط والفعالية المشبكية كالسيوم الخلايا النجمية، ويُعدل النقل الدبقي (يعتمد تحرير الناقل على الكالسيوم من الخلية النجمية) المشبك، وقد يحسن النقل المشبكي في المدى البعيد. هذا يعني بأن خلايا الدبق متضمنة بشكل واضح في إشارة الجهاز العصبي. يمكن أن يعدل تحرير النواقل من قبل الخلايا النجمية الوظيفة أو التابع العصبي، ويغير العتبة من أجل أحداث مختلفة: على سبيل المثال، بتحرير مادة الدبق بشكل محلي سوف تعدل الخلايا النجمية العتبة من أجل اللدونة المشبكية ومن أجل الإثارة العصبية (Martin & Arque, 2005). بضم هذا مع كمونها لإثارة التزامن المكاني حتى 140,000 مشبك، يمكن أن تضيف الخلايا النجمية طبقة جديدة لمعالجة المعلومات والتكامل الكيمياوي الحيوي، بحيث تساعد وتأسس على الأقل بعض الاختلافات بين إمكانيات الأجهزة العصبية للإنسان والفئران وذباب الفاكهة والجبليان (طائفة من الديدان الخيطية).

من الواضح أنه لا يوجد شك فيما يتعلق بسرعة التوصيل العالية للنبضة الكهربائية عبر الخلايا العصبية. إن انتشار كمون الفعل عالي السرعة هذا هو أساساً للتحكم بسلوكنا ولضمان حياتنا أو بقائنا. ليس واضحاً على أية حال فيما إذا كان التوصيل السريع جداً ضرورياً وخاصة للعديد من العمليات الفكرية والمرنة للجهاز العصبي. يعتقد الباحثون بأن انتشار الإشارة في خلايا الدبق بسرعات أقل بستة مرات من كمون الفعل يمكن أن يكون سريعاً بما فيه الكفاية للمساهمة في العديد من العمليات الفكرية والمرنة للجهاز العصبي (Haydon & Araque, 2002).

السوابق

مقدمة

منذ بداياته المبكرة ركز الذكاء الصنعي على التحسينات في مجال واسع لعلوم الحاسوب، وساهم إلى حد كبير في البحث في مجالات تقنية وعلمية مختلفة. يدرس هذا العمل بشكل خاص استخدام تقنية النمذجة الحسابية في مجال الذكاء الصنعي.

هناك نوعان من النماذج الحسابية في سياق الدراسة المقدمة: يعتمد النوع الأول على بديهات البنى الهندسية المعروفة للأنظمة الحيوية والدراسة اللاحقة للسلوك المُثار، ويطبق الباحثون طريقة العمل هذه. أما النوع الثاني فيُستخدم بشكل رئيسي من قبل المهندسين، ويتضمن في الحقائق البديهية أو في تحديد سلوك ما ثم محاولة بناء البنى الهندسية التي تنفذه.

في دراسات العلماء McCullach and Pitts (1943) المذكورين في بداية هذا الفصل مثل Winer (1985) وVon Neumann على علم التحكم الآلي ونظرياتهم في الأتمتة كانت الدراسة الأولى في معالجة مسألة تكامل وجمع العمليات الحيوية بالطرق الهندسية. قدم العالمان McCulloch & Pitts (1943) نموذج الخلية العصبونية الصنعية الذي يحمل اسميهما الآن: الذي هو عبارة عن جهاز ثنائي بحالتين وعتبة ثابتة، يستقبل الاتصالات الاستثارية أو المشابك، الكل بنفس القيمة ومثبطات التأثير الشامل، وقد بسّطا البنية والأداء الوظيفي للخلايا العصبية الدماغية باعتبارها أجهزة ذات m دخل وخرج واحد، وذات حالتين محتملتين فقط: فعالة (نشيطة) وخاملة. في المرحلة الأولية كانت الشبكة العصبونية الصنعية عبارة عن مجموعة من خلايا McCulloch وPitts العصبونية - الجمع بنفس المقياس الزمني – التي تكون فيها نواتج خرج بعض الخلايا العصبونية - الجميع بنفس المقاييس الزمنية – التي تكون فيها نواتج خرج بعض الخلايا العصبونية متصلة بمداخل خلايا عصبونية أخرى. تم الإبقاء والمحافظة على بعض المقترحات المقدمة من قبل Oitts و McCulloch منذ عام 1943 بدون تعديل وطوّرت المقترحات الأخرى، غير أن جميع التشكيلات الرياضية على ANN التي طورت بعد ذلك استخدمت الأنظمة الحيوية كنقطة بداية لدراسات الشبكات العصبة الحيوية بدون زعم أنها نماذج دقيقة ومضبوطة. إن النهضة الحديثة لـــ ANN هي امتداد واسع ناتج عن تمثيل بعض النماذج الملحقة (المثارة) بخصب من قبل علماء الأحياء (Hopfield, 1989).

الشبكات العصبونية الصنعية

إن الحواسيب القادرة على تنفيذ 100 مليون عملية في عشر الثانية غير قادرة بنفسها على فهم معنى الأشكال المرئية، أو على تمييز الأنواع المختلفة من الأجسام. نجحت أنظمة الحساب

التسلسلية في حل المشاكل الرياضية والعلمية، وفي خلق ومعالجة وتخزين قواعد البيانات، وفي الاتصالات الكترونية، وفي معالجة النصوص والرسومات والتحرير الآلي للنصوص. كما نجحت حتى في جعل وظائف التحكم بالأجهزة الكهربائية أكثر فعالية وكفاءة وسهلة الاستعمال، هذه الأنظمة أمية عملياً في تفسير العالم.

تعتبر هذه الصعوبات نموذجية لأنظمة الحاسبات المعتمدة على فلسفة النظام التسلسلي للعالم (Neumann, 1956)، التي دفعت أجيالاً من الباحثين للتركيز على تحسين وتطوير أنظمة معالجة معلومات جديدة – ANN أو CS – تحل المشاكل اليومية بنفس الطريقة التي يعمل بها الدماغ البشري. يوجد لدى هذا العضوي الحيوي خصائص وميزات مختلفة مرغوب بها جداً من أجل أي نظام معالجة رقمي: فهو متين وقوي وقادر على احتمال الصدع، حيث تموت خلايا عصبية كل يوم دون أن تؤثر على أدائه الوظيفي، كما أنه مرن حيث أنه يُضبط ويُكيف مع البيئات الجديدة من خلال التعلّم "السقراطي" (أي من خلال الأمثلة). ولا يتطلب بحد ذاته برمجة بالضرورة، ويمكنه إدارة المعلومات المنتشرة (متناقضة أو مع تشويش)، وهو متواز إلى حد كبير، وبالتالي فهو فعال (فعال زمنياً)، كما أنه صغير الحجم مدمج ويستهلك طاقة صغيرة. إن دماغ الإنسان هو بالحقيقة حاسوب قادر على تفسير المعلومات الغامضة وغير الدقيقة القادمة من الحواس بسرعة فائقة: فبإمكانه أن يميز الهمس في غرفة صاخبة، وأن يميز وجهاً في ممر مظلم، وأن يقرأ ما بين السطور. وعلى نحو مذهل أكثر فإنه يتعلم خلق تمثيلات داخلية تجعل هذه القدرات ممكنة بدون تعليمات صريحة وواضحة ومن أي نوع كان، تحاكي ANN و CS الشبكات العصبية الحيوية من حيث أنها لا تتطلب برمجة المهام بل تعتمد التعميم والتعلم من التجربة. تُركب الـــ ANN الحالية من مجموعة من عناصر معالجة بسيطة جداً (PE) تحاكي الخلايا العصبية الحيوية، ومن عدد محدد من الاتصالات بينها. وهي لا تنفذ تعليمات بل تستجيب بالتوازي الإدخالات المقدمة والمعطية، ويمكنها أن تعمل وتؤدي وظيفة ما بشكل صحيح حتى عندما يكون الـــ PE أو الأداء الوظيفي لموقفات الاتصال أو المعلومات مترافقة بمستوى معين من الضجيج. وبالتالي فهي نظاماً متسامحاً (قادراً على احتمال الضجيج والأخطاء) وقادراً على التعلّم عبر عمليات تدريب تُعدل القيمة المرافقة لاتصالات الـــ PE لضبط الخرج المقدم من قبل النظام في استجابته للمدخلات. لا تخزن النتيجة في موقع ذاكرة. إنها حالة الشبكة التي يتم الوصول عندها إلى توازن. لا تكمن معرفة وقوة أي شبكة عصبونية صنعية في تعليماتها، وإنما في خصائصها الهندسية غير المتغيرة بالحجم والشكل (موقع PE والاتصالات بينها)، وفي قيم الاتصالات (الأوزان) بين PE، وفي التوابع المحددة، لعناصرها وآليات التعلّم.

تقدم CS بديلاً للحسابات الكلاسيكية لمشاكل العالم الحقيقي التي تستخدم المعرفة الطبيعية (قد تكون مجهولة وغير دقيقة ومتناقصة وغير كاملة). كما يكون تحسين البرنامج التقليدي بحيث

يعطي كافة الإمكانيات والاحتمالات بالنسبة لها مهمة مستحيلة، أو على الأقل مرهقة جداً وغالية الثمن. يمكننا أن نجد في البحث Pazos (1991) عدة أمثلة لتطبيقات CS ناجحة: معالجة الصوت والصورة، تمييز الأشكال، واجهات تكيفية لأنظمة إنسان/آلة، التنبؤ، التحكم والأمثلة، ترشيح الإشارات، ... وهلم جراً.

أنوع ANN المختلفة

منذ البدايات المبكرة لـــ ANN طور الباحثون عدداً كبيراً من أنواع الـــ ANN وتطبيقاتها، من مفهوم PE البسيطة على أنها نموذج عن الخلية العصبة الطبيعية واتصالاتها الهائلة. حتى بالرغم من أن كافة هذه الأنواع متشابهة من حيث الخلايا العصبونية والاتصالات المتعلقة بها، فإنها تتنوع وتختلف على نحو كبير بالخصائص الهندسية (الطبولوجيا)، وبالديناميك (الحركة) وبالتغذية والتوابع. كما أن لديها أيضاً – باستمرار – العديد من التحسينات والتنوع في مجال خوارزميات التعلم. يطرح البعض أنواع تعلم جديدة، بينما يقدم الآخرون تعديلات بسيطة على الخوارزميات الموجودة بغية الوصول إلى السرعة اللازمة والتعقيد الحسابي. من جهة أخرى، فوجود مثل هذه الكمية الكبيرة من الإمكانيات يعتبر ميزة إيجابية، حيث يسمح ذلك بتجريب وتدريب أنواع مختلفة من الشبكات. من جهة أخرى فإنها تطرح على الأقل نوعين من الشك والارتياب. الأول: كيف لنا أن نعرف ما هو الخيار الأفضل لحل مشكلة محددة؟، وبالحديث رياضياً فإنه من المستحيل معرفة أن الخيار النهائي هو الأفضل فعلاً، والثاني: ألن يكون من الأفضل انتظار التحسينات المستقبلية التي ستساهم جوهرياً بحل مشاكل ANN بدلاً من معالجتها بالأدوات المتوفرة حالياً؟.

على الرغم من هذا يبقى صحيحاً فإن كافة إمكانيات التصميم – من أجل البنية الهندسية، وكذلك من أجل عملية تدريب ANN – تُوجّه باتجاه جعل مستوى الخطأ أصغرياً أو باتجاه تقليل زمن تعلّم النظام. وهذا بحد ذاته هو عملية أمْثلة آلية العمل – في هذه الحالة لـــ ANN – حيث علينا أن نجد الحل للعديد من بارامترات العناصر والاتصالات بينها.

باعتبار ما تم قوله حول التحسينات المستقبلية الممكنة التي تقوم بأمثلة ANN بالنسبة للخطأ وزمن التدريب الأصغريين، سيكون نموذجنا هو الدارات الدماغية التي تعتبر مساهمة عناصر الـــ CS فيها حاسمة لمعالجة المعلومات. من أجل تصميم دمج وضم هذه العناصر في ANN وتطوير عملية تعلّم ANGN الناتجة، التي تسمح لنا باختبار ما إذا كان هناك تحسين في هذه الأنظمة، قمنا بتحليل طرق التدريب الرئيسية الموجودة التي ستُستخدم للتطوير. حللنا طرق التدريب المُراقب وغير المُراقب والطرق الأخرى التي تستخدم أو تجمع بعض ميزاتها وتكمل التحليل مثل التدريب بالتعزيز، والتدريب الهجين، والتدريب التطويري.

بعض القيود المرصودة

لقد أظهرت عدة تجارب بالـــ ANN وجود تضاربات وتعارضات بين الأداء الوظيفي لـــ CS والشبكات العصبية الحيوية ناتجة عن استخدام طرق لا تعكس الواقع والحقيقة. على سبيل المثال في حالة شبكة Perceptron متعددة الطبقات – التي تمثل CS بسيطة – تمتلك الاتصالات المشبكية بين الـــ PE أوزاناً يمكن تكون استثارية أو تثبيطية، بينما في الجهاز العصبي الطبيعي تمثل الخلايا العصبية هذه الوظائف وليس الاتصالات. تشير الأبحاث الحديثة (Perea & Araque, 2002) بأن خلايا الـــ GS وبشكل محدد أكثر الخلايا النجمية، تلعب دوراً هاماً. يتعلق القيد الآخر بخوارزمية التعلّم المعرفة بالانتشار العكسي (الخلفي) "Backpropagation" الذي يتضمن أن تغير قيمة الاتصالات يتطلب نقل إشارة الخطأ باتجاه الخلف في الـــ ANN. لقد تم بشكل تقليدي افتراض أن هذا السلوك مستحيل في خلية عصبية طبيعية، فوفقاً لنظرية الاستقطاب الديناميكي للعالم Cajal (1904) – لا يمكن إرسال المعلومات عكسياً بشكل فعال عبر المحوار للوصول إلى الجسم الحيوي. كشفت الأبحاث الجديدة على أية حال أنه يمكن للخلايا العصبية أن ترسل معلومات إلى الخلايا قبل المشبكية وفق ظروف وشروط معينة إما بوساطة الآليات الموجودة في التغصنات، أو عبر التدخلات المختلفة لخلايا الدبق كالخلايا النجمية.

إذا كان التعلّم مُراقباً فهذا يتضمن وجود "مدرب" الذي يعني في بيئة الدماغ مجموعة من الخلايا العصبية التي تتصرف بشكل مختلف عن بقية الخلايا لتوجيه العملية. في الوقت الحاضر، لا يمكن إثبات وجود هذا النوع من الخلية العصبية حيوياً. لكن يبدو أن الـــ CS متضمنة بقوة في هذا الاتجاه، وقد تكون العنصر الذي يشكل المدرب الذي إلى حد الآن لم يُدرس أو يؤخذ بالاعتبار.

هذه الفروقات بين نماذج الانتشار العكسي والنموذج الطبيعي ليست هامة جداً بنفسها. لم يستدع تصميم النماذج الصنعية الحصول على نسخة مثالية وتامة للنموذج الطبيعي، وإنما ستدعى سلسلة من السلوكيات التي يقترب أداؤها الوظيفي النهائي منه قدر الإمكان. على الرغم من ذلك، فلا مفر من التشابه القريب بين الاثنين لتحسين الخرج وزيادة تعقيد ANN، وهذا قد يؤدي إلى سلوكيات وتصرفات أكثر ذكاءً. في هذا السياق، تحلل الدراسة الحالية إلى أي مدى تساهم الاكتشافات الأخيرة في علم الأعصاب (Araque et at. 2001; Perea & Araque, 2002) في تلك الشبكات: الاكتشافات التي نشأت من النشاط المخي في المناطق التي يُعتقد بأنها متضمنة في عملية التعلّم ومعالجة المعلومات (Porto, 2004).

أخيراً، يجب أن نتذكر بأن تحديث نماذج ANN الموجودة باتجاه تحسين وتطوير بنى هندسية جديدة مشروط بالحاجة لدمج البارامترات الجديدة في خوارزميات التعلّم، التي يمكن أن تضبط قيمها. إن البارامترات الجديدة التي تزود نماذج PE للـــ ANN بالوظائف الجديدة هي أصعب في

الحصول عليها من تحقيق أمثلية أغلب الخوارزميات المستعملة بكثرة، التي تزيد خرج الحسابات وتعمل أساساً على الجانب الحسابي للخوارزمية.

ستحلل الدراسة المقدمة ضم أو دمج عناصر جديدة في الشبكات الموجودة، ولن تُعقد هذه الطريقة عملية التدريب على نحو زائد، لأننا نطبق طريقة تدريب هجينة تجمع التدريب المُراقب وغير المُراقب، سيتم توضيح أدائها الوظيفي بالتفصيل لاحقاً.

في رأينا ما زالت ANN في طور التحسين والتطور، وربما مازالت في مراحلها الأولية، وإمكانياتها الحقيقية أبعد ما تكون عما تم التوصل إليه أو حتى عما يشك في الوصول إليها.

شبكات الدبق العصبونية الصنعية

مقدمة

استخدم العديد من الباحثين الإمكانيات الحالية للحواسيب وفعالية النماذج الحسابية لتوسيع وتطوير النماذج الحسابية "الحيوية"، والوصول إلى أفضل فهم وإدراك للبنية الهندسية والسلوك لكل من الخلايا العصبية الهرمية التي يعتقد بأنها متضمنة في عمليات الذاكرة والتعلّم (Le Ray, Fernandez, Porto, Fuenzalida, & Buno, 2004) والخلايا النجمية (Porto, 2004، Perea & Araque, 2002). أعطت هذه النماذج فهماً أفضل للأسباب والعوامل المتضمنة في أداء وظيفي محدد للدارات الحيوية. سيستخدم العمل المقدم هذه الرؤى الجديدة للتقدم والارتقاء في مجال العلوم الحاسوبية والذكاء الصنعي بشكل ملموس أكثر.

نقترح ANGN التي تتضمن كلاً من الخلايا العصبونية الصنعية وعناصر التحكم بالمعالجة التي تمثل الخلايا النجمية، والتي يتبع أداؤها الوظيفي الخطوات المُطبقة بنجاح في بناء واستخدام CS: التصميم، التدريب، الاختبار والتنفيذ.

أيضاً، بما أن الدراسات الحسابية للتعلم مع ANN قد بدأت التلاقي والتقارب نحو طرق الحوسبة التطويرية (Dorado, 1999)، فإننا سوف ندمج الأمثلة في تعديل الأوزان (وفقاً لنتائج النماذج الحيوية) مع استخدام الخوارزميات الوراثية (GA) بغية الحصول على الحل الأفضل لمشكلة ما معطية. وُجدت هذه التقنية التطورية لتكون ذات فعالية كبيرة في طور تدريب CS (Rabuňal, 1998)، لأنها تساعد في تكيّف CS للحل الأمثل تبعاً للإدخالات التي تلج إلى النظام ونواتج الخرج التي يجب أن ينتجها النظام. تحدث ظاهرة التكيف هذه في الدماغ بفضل لدونة عناصره، ويمكن التحكم بها جزئياً بواسطة GS، وهذا هو السبب الذي دفعنا لاعتبار GA كجزء من "الدبق الصنعي".

إن نتيجة هذا الدمج هو طريقة تعلّم هجينة مشروحة في الفقرات اللاحقة مع مقارنتها بالطرق الأخرى.

في هذه الدراسة النظرية، تم توجيه تصميم ANGN نحو المشاكل الكلاسيكية المحلولة بواسطة الشبكات البسيطة (أي الشبكات متعددة الطبقات). على الرغم من أن البحث المستقبلي قد يؤدي إلى تصميم النماذج في شبكات أكثر تعقيداً. يبدو أنه من المنطقي البدء بتصميم هذه النماذج الجديدة مع ANN بسيطة وتوجيه آخر الاكتشافات على الخلايا النجمية والخلايا العصبية الهرمية في معالجة المعلومات باتجاه استخدامها في الشبكات الكلاسيكية، بما أن التحكم بالاتصالات المغررة والموهنة في الدماغ يتعلق بتكيف ولدونة الاتصالات، والذي يؤدي إلى توليد طرق التفعيل والتنشيط. يمكن بالتالي أن تحسّن هذه العملية تصنيف الأشكال وتمييزها بواسطة ANGN. تكمن أهداف هذه الدراسة بالآتي: تحليل إمكانيات تعديل النشاط المشبكي الصنعي الذي لم يُدرس حتى الآن، اقتراح المنهجية التي تُطبق هذه الإمكانيات على CS المرتبطة كلياً بالشبكات متعددة الطبقات أمامية الانتشار بدون انتشار عكسي واتصالات جانبية، والمقصورة لحل مسائل التصنيف وتمييز الأشكال البسيطة.

تحليل النماذج والفرضيات على الخلايا النجمية

نعلم بأن الحمض الأميني (كلوماتات) المحرر من الوسط الخارجي للخلية من قبل خلية نجمية أو من قبل خلية قبل مشبكية يمكن أن يؤثر على خلية نجمية أخرى، أو على خلية قبل مشبكية أخرى، أو على خلية بعد مشبكية. إذا كان الحمض الأميني (كلوماتات) الواصل إلى خلية بعد مشبكية قادماً مباشرة من خلية قبل مشبكية، يحدث كمون فعل (AP) بسرعة أكبر وينتهي نهاية مبكرة تقريباً. وإذا تم تحرير الكلوماتات من قبل خلية نجمية مُنشطة بكلوماتات من خلية قبل مشبكية، فيحدث AP أكبر (Pasti et al., 1997). بما أن عملية التأثير المتحكمة بالخلايا النجمية أبطأ، فسيتم اكتشاف الـــ AP المُثار من قبلها بسهولة بسبب بطئها. نحن نعلم بأن تنشيط الخلايا النجمية والاتصالات عبر إشارات الكالسيوم هو عملية بطيئة، إذا ما قارناها بالنشاط العصبي (Araque, 2002). يمكن استخلاص نفس النتائج من تأثيرها على المشبك بين خليتين عصبيتين نشطت نواقلهما العصبية الخلية النجمية، التي تكون أبطأ بـــ 1.000 مرة من انتشار النبضة (الدفعة) في الخلايا العصبية (60 ثانية للخلية النجمية - 60 ميلي ثانية للخلية العصبية). أدى هذا البطء إلى اجراء دراسات على تمثيل ANGN لكل نموذج تدريب خلال أكثر من دورة واحدة أو تكرار واحد. إذا قُلّد هذا البطء فإن ANGN ستحتاج إلى n دورة أو تكرار لمعالجة كل نموذج دخل.

حتى الآن لم نذكر الفكرة، بأنه إذا ما أثرت الخلايا النجمية ببطء شديد فمن المحتمل أن تكون متضمنة في عمليات أكثر تعقيداً للدماغ، لأن أنواع الكائنات الحية الأقل تطوراً لديها خلايا نجمية أقل، وتعتمد على خلاياها العصبية للرد بسرعة على محفزات الصيد والهروب.

بما أن البشر يعتمدون عادةً أقل على ردود الأفعال السريعة وأكثر على الإمكانيات والقدرات مثل التفكير والتحدث، فقد تكون الخلايا النجمية هي العناصر التي تساهم في تلك العمليات الخاصة. بدأ تنفيذ البحث في هذا الموضوع على خلفيات مؤسسة بشكل جيد.

أيضاً يجب أن نتذكر بأن مساهمة الخلايا النجمية بأوزان اتصالات ANGN تحدث وفقاً لعامل الزمن، آخذين بالاعتبار حقيقة أنها تعمل ببطء، وأن استجابتها لا خطية. وسيكون أمراً مثيراً معرفة كيفية تأثير الخلايا النجمية على CS مع اعتبار تأثيرها على المشابك وفقاً لنشاط الخلايا العصبية بمرور الوقت. إن نشاط الخلايا العصبية هو الأكثر شدةً أما تأثير الخلايا النجمية على اتصال ما أو على خلية نجمية أخرى تؤثر على مشبك شبكة آخر فهو الأكبر ... وهكذا.

نحن نعلم بأنه يوجد 10 خلايا نجمية لكل خلية عصبية، وأن كل خلية نجمية يمكن أن تؤثر على آلاف الخلايا العصبة عبر كافة تفرعاتها. يمكن أن تنمو نسبة الخلايا النجمية/الخلايا العصبة إلى 1/50 في المناطق ذات النشاط الإدراكي الأكبر. يوجد لدى الخلايا النجمية مستويا تفعيل: الخلايا العصبية مع اتصالاتها، والخلايا النجمية مع اتصالاتها، وتأثيرها على الاتصالات بين الخلايا العصبية.

إن استجابة الخلايا النجمية ليست "كل شيء أو لا شيء"، وإنما يمكن أن تكون استجابة الخلية العصبية "كل شيء أو لا شيء" وفقاً لنوع الشبكة المبنية وتابع تفعيلها.

الأحداث المخية المدروسة

بدراسة الأداء الوظيفي للخلايا العصبية الهرمية والخلايا النجمية (Porto, 2004) سويةً مع الفرضيات الموجودة (Le Ray et at., 2004; Perea & Araque, 2004)، فإن الأحداث المخية الرئيسية التي يجب أن تؤخذ بالحسبان، وتُعكس في CS هي التالية:

1. زيادة كمون القدح في خلية بعد مشبكية.
2. نقصان احتمال تحرير الناقل العصبي في المشبك الفعال.
3. نقصان احتمال تحرير الناقل العصبي في مشابك أخرى أكانت قريبة أم لا.
4. زيادة احتمال تحرير الناقل العصبي في المشبك الفعال.

5. زيادة احتمال تحرير الناقل العصبي في مشابك أخرى أكانت قريبة أم لا.

6. يمكن أن يؤثر تحرير النواقل العصبية لخلية نجمية على خلية قبل مشبكية أو على خلية بعد مشبكية أو على كليهما. وهذا ما يمكنه فتح طريق التأثير على مشبك آخر يكون بعيداً جداً عن تلك التي أثارت زيادة الكالسيوم قبل تحرير الناقل العصبي.

7. التثبيط للأفعال التثبيطية لخلايا عصبونية قبل مشبكية في مشبك ما، بمعنى أن التثبيط الذي يمكن أن يحدث لن يعمل بشكل صحيح، وبالتالي قد يحدث إرسال مشبكي أو لا يحدث اعتماداً على كيفية رد المحاوير الأخرى في ذلك المشبك. تختلف هذه النقطة عن النقطة 2 لا يحدث فيها إرسال مشبكي، بينما يمكن أن يحدث ذلك هنا بغض النظر عن تأثير المحوار التثبيطي الذي ثُبط من قبل الخلية النجمية.

8. تثبيط الأفعال الاستثارية لخلايا عصبونية قبل مشبكية في مشبك ما، أي أنه لن تحدث الإثارة. ويمكن أن يحدث إرسال مشبكي أو لا يحدث اعتماداً على أفعال المحاوير الأخرى في ذلك المشبك. تختلف هذه النقطة أيضاً عن النقطة 2، فقد يحدث إرسال مشبكي أو لا يحدث، غير أن ذلك لا يعتمد على تأثير المحوار الاستثاري الذي ثُبط من قبل الخلية النجمية.

9. إثارة الأفعال الاستثارية لخلايا عصبونية قبل مشبكية في مشبك ما. أي أن الإثارة ستكون فعالة أكثر، وقد يحدث إرسال مشبكي أو لا يحدث اعتماداً على سلوك المحاوير الأخرى في ذلك المشبك.

من الواضح أن سلوك الخلايا العصبية والخلايا النجمية يفسح مجالاً لبعض الطرق، ويستثني الطرق الأخرى. كالعين التي تخلق تبايناً لكي تميز بين بعض الصور المحيطة.

احتمالات تأثير العناصر والظواهر المخية على CS

فتح تحليل النشاطات المخية طرقاً مختلفة لتحويل CS إلى ANGN. وهذا بحد ذاته يزودها بإمكانية تحسن مساهمتها في معالجة المعلومات. تعرض الفقرات التالية الاقتراح النظري الذي يتضمن سلسلة من التعديلات مع أساس حيوي هام.

صُنفت الإمكانيات تبعاً لما يحدث مع الاتصالات بين الخلايا العصبية وقيمة التفعيل للخلايا العصبية ومجموعات من التوليفات بينها.

الاتصالات بين الخلايا العصبة

a. **دراسة كل خلية عصبية بشكل إفرادي:**

الشرط هو أن تكون خلية عصبية واحدة مُنشطة. وفقاً لتابع التفعيل الذي نريد أن نستخدمه يمكننا أن نعّين في نظام الاختبار قيمة الخرج التي سوف تنشط الخلية العصبية، مثل عتبة (قيمة ما بين 0 و1)، أو خطية (قيمة ميل الخط المستقيم) ... وهلم جراً. إذا نُشطت خلية من الخلايا العصبية أو لم تُنشط X مرة، فإن أوزان الاتصالات التي تلج إلى تلك الخلية العصبية أو تغادر منها أو كلاهما معاً تزداد أو توهن على الترتيب بنسبة مئوية محددة من قيمها الحالية. وهذا يعني بأننا نعزز الاتصالات التي تصل إلى الخلية و(أو) يحدث في داخلها كمون فعل يحرض ويثير الوصلات العصبية الفعّالة أكثر. يمكننا محاولة تعزيز أو إضعاف الاتصالات التي تغادر الخلية العصبية أو تلك تلج إلى خلية عصبية أو كلاهما معاً ومقارنة النتائج.

b. **دراسة خليتين عصبيتين متماستين نشيطتين أو خاملتين خلال X تكرار متتالي:**

المعتمد جزئياً على مسلمة العالم Hebb(1949): يُعزز فقط الاتصال الذي يجمع هاتين الخليتين العصبيتين، ويوُهن الاتصال آنف الذكر وكافة الاتصالات التي تلج إلى الخلية العصبية المصدرية و(أو) تلك التي تغادر الخلية العصبية المقصودة تُعزز أو توهن.

c. **دراسة الخلايا العصبية لنفس طبقة الخلية العصبية النشيطة أو الخاملة خلال تكرار متتالي:**

تستند هذه الدراسة إلى حقيقة أنه يمكن لخلية نجمية أن تؤثر على عدة خلايا عصبية بآن واحد: تُعزز الاتصالات التي تلج أو تغادر الخلايا العصبية المجاورة أو لكلا النوعين (في الحالة التي تكون فيها الخلية المدارة نشطة خلال تكرار)، وتوهن الاتصالات التي تلج أو تغادر الخلايا العصبية المجاورة أو لكلا النوعين (في الحالة التي تكون فيها الخلية العصبية المدارة خاملة خلال تكرار).

d. مجموعة توليفات من a وb وc.

قيمة تفعيل الخلايا العصبية

إن قيمة تفعيل خلية عصبونية صنعية في اللحظة الحالية متأثرة. وهذا الفعل ليس تكرارياً لأنه لا يُؤخذ بالاعتبار لحساب تابع الـــ NET في خلية عصبونية صنعية (قيمة خرجها أو قيم خرج خلايا عصبونية أخرى). تعتبر قيمة التفعيل لخلية عصبونية تبعاً لنسبة النشاط المئوية الخاصة بها أو الخاصة بخلايا عصبونية أخرى.

a. **دراسة كل خلية عصبونية بشكل إفرادي:** قيمة التفعيل للخلية العصبونية التي كانت نشيطة أو خاملة خلال تكرار متتالي تُزاد أو تُنقص.

b. **دراسة خليتين عصبونتين متماستين نشيطتين أو خاملتين خلال تكرار متتالي: بإتباع مسلمة العالم Hebb**: تُزاد أو تُنقص قيمة التفعيل لخلية عصبية بعد مشبكية أو لخلية عصبية قبل مشبكية إلى درجة معينة. تُزاد وتنقص قيم التفعيل للخليتين العصبونيتين المتشابكتين ولكافة الخلايا العصبونية المتماسة.

c. **دراسة الخلايا العصبونية المتجاورة (لنفس الطبقة) لخلية عصبونية نشطة أو خاملة خلال تكرار متتالي:** بالاستناد إلى حقيقة مفادها أن خلية نجمية تؤثر على عدة خلايا عصبونية بآن واحد، فإن قيمة التفعيل لتلك الخلايا العصبونية المتجاورة (في الحالة التي تكون فيها الخلية العصبونية المدارة نشطة أو خاملة خلال تكرار) تُزاد أو تُنقص على الترتيب.

d. مجموعة توليفات من a وb وc

توليفات من الحالات السابقة

ترمز التوليفات الناتجة إلى تثبيط التثبيط، وتثبيط الإثارات، وإثارة التثبيط، وإثارة الإثارات لخلية أو لعدة خلايا عُصبونية، وللاتصالات التي تلج إلى الخلية العصبونية أو تغادرها، ... وهلم جراً. عندما تكون خلية عصبونية محددة خاملة خلال تكرار متتالي، وتصبح نشطة خلال Z تكرار متتالي، لا تُنقص قيمة الاتصالات التي تلج إليها أو تغادرها أو كليهما معاً. وعندما تكون خلية عصبونية ما خاملة خلال تكرار متتالي، وتصبح نشطة خلال Z تكرار متتالي، فإن اتصالاتها الخارجة السلبية المرافقة تصبح موجبة. هذا مثال على إثارة مشابك تثبيطية. عندما تكون خلية عصبونية ما نشيطة خلال تكرار متتالي، وتصبح خاملة خلال Z تكرار متتالي لا تُعزز الاتصالات المرافقة. وعندما تكون خلية عصبونية ما نشيطة خلال X تكرار متتالي، وتصبح خاملة خلال Z تكرار متتالي، فإن اتصالاتها الخارجة المرافقة تصبح 0. وهذا مثال على تثبيط مشابك استثارية.

اقتراح الأداء الوظيفي لـ ANGN

يسلك بناء ANGN وبناؤها الوظيفي كافة مراحل CS، ابتداءً بتصميم البنية الهندسية للشبكة ثم بأطوار التدريب والاختبار والتنفيذ.

طور التصميم

بغية التبسيط، اُعتمد التصميم على أساس البنى الهندسية متعددة الطبقات أمامية الانتشار التي تكون موصولة كلياً بدون انتشار عكسي أو اتصالات جانبية ومُوجه نحو تصنيف وتمييز الأشكال.

طور التدريب

قمنا بتصميم طريقة تدريب هجين تدمج ما بين التعلّم غير المُراقب (المرحلة الأولى) مع التدريب المراقب الذي يستخدم التقنية التطورية لــ GA (المرحلة الثانية).

بما أن GA تتطلب وجود سلاسل فردية، فإن المرحلة الأولى تخلق مجموعة سلاسل فردية للعمل معها. تتألف كل سلسلة فردية للـــ GA من عدد من القيم يساوي أوزان الاتصالات في ANGN، وتشكل كل مجموعة اختيارية من الأوزان كافةً سلسلة فردية مختلفة.

تتألف المرحلة الأولى من تعلّم غير مُراقب معتمد على سلوك الخلايا المخية التي نُمذجت بواسطة بيئة محاكاة الخلية العصبية NEURON (Hines, 1994) في أبحاث وأعمال العلماء Porto (2004)، Araque(2002)، LeRay et at (2004). وتم تحليل الأداء الوظيفي للشبكة مع كافة سلاسلها الفردية. تُعدّل كل سلسلة فردية (أي أوزان الاتصالات) عندما يُمرر كل نموذج تدريب إلى الشبكة وفقاً لما كان عليه نشاط الخلايا العصبونية أثناء مرور ذلك النموذج. من أجل كل سلسلة فردية، يقدم نموذج تدريب أو مثال دخل من مجموعة التدريب إلى الشبكة خلال عدد محدد من المرات أو التكرار. تمثل هذه التكرارات بطء تأثير الخلايا النجمية، وتشكل دورة النموذج. خلال كل تكرار للدورة تُعدل الاتصالات طبقاً للقواعد المشروحة سابقاً، والتي تعتمد عموماً على نشاط الخلايا العصبونية. ما إن تنتهي دورة النموذج، نقوم بحساب خطأ الشبكة من أجل ذلك النموذج لإيجاد الفرق بين الخرج المكتسب والمطلوب. نُخزن خطأ الشبكة لكل نموذج. بعد ذلك، عندما تُمرر كافة نماذج التدريب إلى الشبكة نحسب الخطأ المتوسط التربيعي (MSE) لتلك السلسلة الفردية، بما أنه عند بداية دورة نموذج ما تكون السلسلة الفردية المطبقة على الشبكة هي مرة أخرى الأولى من مجموعة السلاسل الفردية المستخدمة. لقد اخترنا الـــ MSE لأنه يعطي قياساً نسبياً للأمثلة التي تُغذى إلى الشبكة من أجل مقارنة الخطأ بين البنى الهندسية المختلفة والخطط التدريبية. أيضاً، فإن التربيع في بسط الكسر يفضل حالات السلاسل الفردية التي يكون خرج الشبكة لأجلها قريباً من القيم المثالية لكافة الأمثلة. تُكرر العملية نفسها لكافة السلاسل الفردية. تُشكل هذه المرحلة تدريباً غير مُراقب، لأن تعديلات أوزان الاتصالات لا تأخذ بالحسبان خطأ الخرج، وإنما تحدث في أي وقت تبعاً لتردد تفعيل كل خلية عصبونية مقلّدةً بذلك التعزيزات والمنع التي يمكن أن تكون مثارة في الدماغ من قبل الخلايا النجمية (Perea & Araque, 2004)، أو بإزالة استقطاب التيارات الأيونية (LeRay et at., 2004).

مرحلة التدريب الثانية والأخيرة هي طور التدريب المُراقب المتضمن في تطبيق GA على السلاسل الفردية وفقاً لــ MSE المُنتج من قبل الشبكة مع كلٍّ من السلاسل الفردية والمُخزن أثناء مرحلة التدريب الأولى (Rabuñal, 1998). ما إن يُخزن MSE لكافة السلاسل الفردية تنفذ الـــ GA في

مرحلة ثانية التصالبات والطفرات الموافقة، وتختار السلاسل الفردية الجديدة التي سيتم بها تكرار المرحلتين الأولى والثانية حتى الحصول على أقل خطأ ممكن ومن المفضل ألا يكون هناك خطأ. تُعتبر المرحلة الثانية تدريباً مراقباً لأن GA تأخذ بالحسبان الخطأ المنتج من قبل الشبكة لاختبار السلاسل النهائية التي سيتم تطبيق التصالب والطفرة عليها، بمعنى أنها تقوم بتغيير الأوزان تبعاً لذلك الخطأ. يطبق نظام تدريب GA مواصفات GA المصاغة من قبل العالم Holland (1975).

طور الاختبار التنفيذ

يزودنا تدريب ANGN بالسلسلة الفردية التي تسمح لنا أوزانها بالحصول على الخطأ الأصغر في الخرج. خلال الطور الحالي، نستخدم هذه السلسلة الفردية لاختبار فيما إذا كان الخرج المكتسب من قبل النموذج صحيحاً، أي إذا كانت قابلية تعميم ANGN صحيحة مع أشكال (نماذج) دخل تختلف عن الأشكال المستخدمة خلال مرحلة التدريب، وتحضير ANGN لاستخدامها التالي. في هذا الطور، وفي سياق التنفيذات المتعاقبة، فإن عناصر التحكم بنشاط الشبكة التي تمثل الخلايا العصبية الهرمية والخلايا النجمية التي تتدخل أثناء مرحلة التدريب غير المُراقب عليه - تبقى نشيطة، وبالتالي تكون هذه العناصر المدمجة جزءاً من النموذج في كافة مراحله، وتساهم مباشرةً في معالجة المعلومات تماماً كالخلايا العصبونية الصنعية. ستقدم أشكال (نماذج) الدخل نفسها خلال التكرارات التي حُدِّدت في طور التدريب، وبموجب ذلك تسمح للعناصر الجديدة بتنفيذ نشاطها.

مقارنة بين طريقة التعلّم المقترحة والطرق الموجودة

يقارن هذا القسم طريقة التعلّم المقترحة مع عدة طرق مطبقة عادة في CS، ويناقش بعض التشابهات. ويكمن غرضنا في التعليق على الاختلافات الموجودة وأفضلية أو ميزات هذا المقترح الجديد.

يكمن الاختلاف الأول في لحظة تعديل الأوزان في طريقة الانتشار العكسي والطرق الأخرى التي تستخدم قواعد التعلّم المُراقب. ولا تُعدّل الأوزان في كل مرة يُمرر فيها نموذج (شكل) ما. ما إن تمرر كافة نماذج (أشكال) مجموعة التدريب، حتى يُحسب MSE، ثم على أساس ذلك الخطأ تُعدّل الأوزان مرة واحدة. بعد ذلك تُمرر كامل مجموعة التدريب من جديد، ويحسب MSE مرة ثانية، ثم تنفذ التعديلات ذات الصلة في الأوزان مجدداً، حتى يصبح الخطأ صغيراً قدر الإمكان وتتقارب الشبكة. تعدل الطريقة المقترحة – على أية حال – الأوزان أثناء كل خطوة دورة بغض النظر عن الخطأ المرصود وتبعاً للتفعيلات التي تحدث في كل لحظة. قد تسبب هذه الحالة تأخيراً طفيفاً في الأداء الوظيفي لـ CS ولكنها تحاكي الحقيقة المخية بدقة أكثر.

بالنسبة للمعايير التي يجب أن تُتبع لتعديل الأوزان، فإننا ننسخ وظائف العناصر المخية المنمذجة. أولاً، يقدم هذا الإجراء بعض التشابهات مع تعديلات طريقة التعلّم غير المُراقب للعالم Kohonen، باستثناء الحقيقة الموجودة في طريقتنا التي تُختبر على مسائل التصنيف، حيث لا يوجد تنافس. يقدم العالم Kohonen الشبكات التنافسية التي تصنف نماذج الدخل إلى مجموعات، وتستخدم تعديل أوزان PE بقيمة خرج أكبر أو أقل. ثانياً، بما أن طريقتنا تأخذ بالحسبان كافة تفعيلات الخلايا العصبونية الصنعية، فإننا نعتقد بأنه من المهم التعليق على الفروق مع الطريقة المستخدمة من قبل الشبكات المعتمدة على التأخيرات. تمتلك PE في تلك الشبكات ذواكر تخزن قيم التفعيلات السابقة لتعمل بها في اللحظة الحالية. خلال الطور الأول للطريقة الهجينة المقترحة نقوم غالباً بإحصاء كم خلية عصبونية صنعية نُشطت وليس ما هي القيمة المكتسبة.

تُعزز أو توهن هذه الطريقة بعض الاتصالات. وفقاً للقاعدة العصبية الحيوية المطبقة، فإن الاتصالات قبل أو بعد PE قد تكون مُعززة أو موهنة. آخذين بالاعتبار تعديلات الاتصالات السابقة، نقوم برصد وملاحظة الاتصال المشابه للتكرار، الذي يكون جزئياً، فقط لأن بعض الاتصالات تُعزز أو تُمنع تحت شروط محددة.

على أية حال، بما أن عناصر التحكم الجديدة خارج PE تؤثر على الأوزان بغض النظر عن قيمة التفعيل الحالية لـــ PE، فإنه يمكننا أن نستنتج بأنها ليست حالة تكرار كما في الشبكات التكرارية جزئياً أو كلياً – وإنما هي حالة "تأثير".

قد لا يشير إلى أن العنصر الجديد يُعدّل الاتصالات السابقة فقط، وإنما إلى أن الخلايا العصبونية السابقة قد تُعدّل مقدار المشبك الموافق مثل، كما تم ملاحظته خلال التجارب في أنبوبة الاختبار. وستسمح هذه الحالة المبينة على أساس فرضية Hebb (1949) بدمج الظواهر التي نمذجت في تمكين مشبكي (LeRay et at. 2004, Porto, 2004)، كما يقترح الاستخدام المستقبلي لقاعدة Hebb المستخدمة في التعلّم غير المُراقب لتشكيل تلك التغيرات في الأوزان بجمع هذا الاستخدام مع GA لمتابعة دراسة الأفضليات والميزات لطريقة هجينة من أجل تصنيف الشبكات متعددة الطبقات. لا تتعلق السمة الهامة الأخرى التي تميز ANGN بطور التدريب بل بالتقييم وبطور التنفيذ. عندما تُستخدم الشبكة في طور التنفيذ، فإنه يتم الحفاظ على فعاليات وأعمال التحكم للعناصر الجديدة المدمجة. وهذا يعني أن كل نموذج يجب أن يُمرر n مرة، وn هي عدد التكرارات المختار من دورة النموذج. تحتاج ANGN لـــ n دورة لمعالجة كل نموذج دخل.

التطويرات المستقبلية

لقد بدأنا الآن بتطبيق هذا المقترح النظري على CS واختبار كلٍّ من الإمكانيات المقدمة ومقارنة نتائجها مع تلك الناتجة من شبكة ANN مدربة بالــ GA. درسنا الحل لمشكلة بسيطة بــ ANGN: قلّدنا جهازاً الكترونياً معروفاً بوحدة اتصال متعددة أو Multiplexor (Mux) ذا أربعة مداخل وخرج واحد بواسطة ANGN مع بنية هندسية متصلة كلياً ومتعددة الطبقات أمامية الانتشار بدون انتشار عكسي واتصالات جانبية. كانت النتائج مقنعة، ومازالت التجارب مستمرة.

المراجع

Araque, A. (2002, September). Conversación personal con A. Araque. Institute Cajal (CSIC). Madrid.

Araque, A., Carmignoto, G., & Haydon, P. G. (2001). Dynamic signaling between astrocytes and neurons. Annu. Rev. Physiol, 63, 795-813.

Araque, A., Purpura, V., Sanzgiri, R., & Haydon, P. G. (1999). Tripartite synapses: Glia, the unacknowledged partner. Trends in Neuroscience, 22(5).

Dorado, J. (1999). Modelo de un sistema para la seleccion automática en dominios complejos, con una estrategia cooperativa, de conjuntos de entrenamiento y arquitecturas ideales de redes de neuronas artificiales utilizando algoritmos genéticos. Doctoral thesis. Facultad de Informática. Universidade da Coruña.

Haydon, P. G. (2001). Glia: Listening and talking to the synapse. Nat. Rev. Neurosci., 2, 185-193.

Haydon, P. G., & Araque, A. (2002). Astrocytes as modulators of synaptic transmission. In A. Volterra, P. Magistretti, & Haydon (Eds.), Tripartite synapses: Synaptic transmission with glia (pp. 185-198). Oxford University Press.

Hebb, D. O. (1949). The organization of behaviour. New York: J. Wiley.

Hines, M. (1994). The NEURON simulation program. In J. Skrzypek & Norwell (Ed.), Neural network simulation environments (pp. 147-163). MA: Kluwer.

Holland, J. H. (1975). Adaptation in natural and artificial systems. Ann Arbor: University of Michigan Press.

Hopfield, J. (1989). Neural networks: Algorithms and microchardware. Piscataway, NJ: Institute of Electrical and Electronics Engineers.

Kimelberg, H. K. (1983). Primary astrocyte culture. A key to astrocyte function. Cellular and Molecular Neurobiology, 3(3) 1 -16.

Kimelberg, H. K. (1989). Neuroglia. Rev. Investigacion y Ciencia, 153, 44-55.

Kuwada,J. Y. (1986). Cell recognition by neuronal growth cones in a simple vertebrate embryo. Science, 233, 740-746.

Largo, C., Cuevas, P., Somjen, G. G., Martin del Rio, R., & Herreras, O. (1996). The effect of depressing glial function in rat brain in situ on ion homeostasis, synaptic transmission, and neuron survival. Journal Neurosci., 16, 1219-1229.

LeRay, D., Fernández, D., Porto, A., Fuenzalida, M., & Buño, W. (2004). Heterosynaptic metaplastic regulation of synaptic efficacy in CA1 pyramidal neurons of rat hippocampus. Hippocampus.

LeRoux, P. D., & Reh, T. A. (1986). Regional differences in glial derived factors that promote dendritic outgrowth from mouse cortical neurons in vitro. Journal Neurosci., 14,4639-4655.

Lorenz, K. (1986). Fundamentos de la etología: Estudio comparado de las conductas. Barcelona: Paidós.

Martín, E. D., & Araque, A. (2005). Astrocytes and the biological neural networks. Artificial Neural Networks in Real-Life Applications (pp. 22-46). Hershey, PA: Idea Group Publishing.

Mauch, D. H., Nagler, K., Schumacher, S., Goritz, C., Muller, E. C., Otto, A., & Pfrieger F. W. (2001).CNS synaptogenesis promoted by glia- derived cholesterol. Science, 294, 1354-1357.

McCulloch, W. S., & Pitts, W. (1943). A logical calculus of ideas immanent in nervous activity. Bulletin of Mathematical Biophysics, 5, 115-133.

Mennerick, S.,& Zorumski,C.F. (1994). Glial contribution to excitatory neurotransmission in cultured hippocampal cells. Nature, 368, 59-62.

Noremberg, M.D., Hertz, L., & Schousboe, A. (1988). Biochemical pathology ofastrocytes. Alan R. Liss Inc.

Pasti, L., Volterra, A., Pozzan, R., &Carmignoto, G. (1997). Intracellular calcium oscillations in aslrocytes: A highly plastic, bidirectional form of communication between neurons and astrocytes in situ. Journal ofNeuroscience, 17, 7817-7830.

Pazos, A., & Col. (1991).Estructura, dinámica y aplicaciones de las Redes de Neuronas Artificiales. Centro de Estudios Ramón Areces, S.A. España.

Perea, G., & Araque, A. (2002). Communication between astrocytes and neurons: A complex language. Journal of Physiology. Paris: Elsevier Science.

Perea, G., & Araque, A. (2004). Properties of synaptically evoked astrocyte calcium signal reveal synaplic information processing by astrocytes. Journal of Neuroscience, in press.

Pfrieger, F.W.,&Barres,B.A. (1997). Synaptic efficacy enhanced by glial cells in vitro. Science, 277,1684-1687.

Porto, A. (2004). Modelos computacionales para optimizar el aprendizaje y el procesamiento de la información en sistemas adaptativos: Redes neurogliales artificiales (RR.NG.AA.). Tesis Doctoral. Universidade da Coruña. A Coruña.

Rabunal, J. (1998). Entrenamiento de redes de neuronas artificiales con algoritmos geneticos. Tesis de Licenciatura. Dep. Computacion. Facultad de Informatica. Universidade da Coruna.

Raff, M.C., Barres, B.A., Burne, J.F., Coles, H.S., Ishizaki & Jacobson, M.D. (1993). Programmed cell death and the control of cell survival: Lessons from the nervous system. Science, 262,695-700.

Rakic, P. (1978). Neural migration and contact guidance in the primate telencephalon. Postgraduated Medical Journal, 54, 25-40.

Rakic, P. (1990). Principies of neuronal cell migration. Experientia, 46, 882-891.

Ramón y Cajal, S. (1904). Textura del sistema nervioso del hombre y los vertebrados. Tomo II. Madrid.

Ramón y Cajal, S. (1911). Histologie du sisteme nerveux de l'homme et des vertebres. Maloine, Paris.

Sanai, N., Tramontin, A., Quiñones, A., Barbaro, N., & Gupta, N. (2004). Unique astrocyte ribbon in adult human brain contains neural item cells but lacks chain migration. Nature 427, 740-744.

Smith-Thier, J. (1975). Fisiopatología: Principios biológicos de la enfermedad (2nd ed). Panamericana. México.

Verkhratsky, A., Orkand, R.K., & Kettenmann, H. (1998). Glial calcium: Homeostasis and signaling function. Physiol Rev, 78, 99-141.

Von Neumann, J. (1956). Probabilistic logics and the synthesis of reliable organisms from unreliable components. In C.E. Shannon & J. McCarthy (Eds.), Automata studies (pp. 43-98). Princeton University Press.

Von Neumann, J. (1956). The Computer and the brain. Yale University Press.

Wiener, N. (1985). Cibernética. Tusqets editores.

الفصل الثاني

الخلايا النجمية والشبكات العصبونية الحيوية

ملخص

الشبكات العصبونية الصنعية هي نموذج مُلهم عصبياً وحيوياً، يحاكي ويقلد الأداء الوظيفي للدماغ. وهي مبينة على أساس التابع العصبوني لأن الخلايا العصبونية تُعرّف كعناصر خلوية مسؤولة عن معالجة المعلومات الدماغية. على أية حال، عرضت الدراسات الحديثة أنه يمكن أن ترسل خلايا نجمية إشارة إلى خلايا نجمية أخرى، كما يمكنها الاتصال تبادلياً مع خلايا عصبية أخرى وهي تقترح دوراً فعالاً أكثر للخلايا النجمية في فسيولوجية الجهاز العصبي ووظائف الدماغ الأساسية. تستدعي هذه الرؤية الجديدة لدور خلايا الدبق في وظائف الدماغ إعادة اختبار رؤيتنا الحالية للشبكات العصبونية الصنعية، والتي يجب أن تتوسع لدراسة شبكات الدبق العصبوني الصنعية. لم يُطبق بعد مفهوم شبكات الدبق العصبوني الصنعية على العلوم الحسابية وعلوم الذكاء الصنعي. على أية حال، فإن تنفيذ شبكات دبق عصبوني صنعية بإدخال خلايا الدبق كجزء من الشبكات العصبونية الصنعية يعد مثمراً وناجحاً للشبكات الصنعية كما هو الحال من أجل الشبكات الحيوية.

مقدمة

إن الشبكات العصبونية الصنعية – هي نموذج مُلهم عصبياً وحيوياً يقلد الأداء الوظيفي للدماغ، وتعتمد على الأسلوب الذي نعتقد بأن الخلايا العصبية تعمل به، لأنها تُعرّف كعناصر خلوية مسؤولة عن معالجة المعلومات الدماغية. يوجد نوعان رئيسيان من الخلايا في الدماغ. الخلايا العصبونية وخلايا الدبق تُشكل الخلايا النجمية بين الأنواع الفرعية الرئيسية الأربعة لخلايا الدبق الخلايا الأكثر شيوعاً في الجهاز العصبي المركزي (CNS). كان يعتقد لفترة طويلة أن وظيفة الخلية النجمية هي مجرد وظيفة داعمة للوظيفة العصبية. على أية حال، عرضت الدراسات الحديثة بأنه بإمكان خلايا نجمية أن ترسل إشارة إلى خلايا نجمية أخرى – مشكلةً نوعاً جديداً من الشبكة الخلوية في الدماغ – كما يمكنها الاتصال بشكل ثنائي الاتجاه مع الخلايا العصبية ما

يقترح دوراً أكثر فعاليةً للخلايا النجمية في وظائف الدماغ الأساسية منظمةً بذلك الإثارية (الإثارة) العصبونية والإرسال مشبكي (للمراجعة انظر Araque Carmignoto, & Haydon 2001) اعتماداً على هذه النتائج الجديدة حيث يعتبر الدبق الآن كشريك نشيط وفعال للمشبك ينظم نقل المعلومات المشبكي بفعالية، بالإضافة إلى معالجة المعلومات العصبونية. تدعو هذه الرؤية الجديدة لدور الخلية الدبقية في وظيفة الدماغ إلى إعادة اختبار رؤيتنا الحالية للشبكات العصبونية الصنعية التي يجب أن تُوّسع لتأخذ بالاعتبار خلايا الدبق لخلق شبكات دبق عصبوني صنعية.

في بعض مناطق الجهاز العصبي تفوق خلايا الدبق الخلايا العصبية عدداً بمقدار 10 إلى 1. الدبق (Glia) (كلمة يونانية الأصل تعني الصمغ) مهم جداً في دعم بيئة الاستقرار الداخلي للخلايا العصبية بالإضافة إلى مشاركتها في الوظائف الأخرى. يوجد هناك ثلاثة أنواع رئيسية لخلايا الدبق في الجهاز العصبي المركزي: astrocytes (خلايا نجمية)، Oligodendroiytes (خلايا غصنية زيتونية) وmicroglia (خلايا دبق ميكروية). تمتلك الخلايا النجمية عمليات عديدة تتفرع في شكل شبه نجمي. تشكل وظائف الخلايا النجمية ما يلي: الدعم البنيوي للخلايا العصبية، التكاثر والانتشار والإصلاح بعد جرح الأعصاب، الاشتراك في الممرات الأيضية التي تُعدل وتُنظم التركيز خارج الخلية للأيونات والنواقل والتفاعلات الحيوية المشتركة في وظائف الخلايا والمشابك.

خلايا التغطية الزيتونية مسئولة بشكل رئيسي عن تشكيل النخاعين حول المحاوير في الجهاز العصبي المركزي. تلعب أغلفة النخاعين دوراً مهماً في تحسين خصائص التوصيل العصبي. بينما تكون الخلايا التغضنية الزيتونية موجودة بشكل محدد في الجهاز العصبي المركزي، فإن النخاعين يُشكّل من قبل خلايا Schwann في الجهاز العصبي المحيطي. أما النوع الثالث من خلايا الدبق - microgLia - فهي أصغر خلايا موجودة في كافة أنحاء الجهاز العصبي المركزي، بحيث تكون وظيفتها كخلايا نظام منيع في الـــ CNS.

إن الخلايا النجمية — أو خلايا الدبق النجمية – مرتبطة عبر موصلات فجوة مشكلةً مدمجاً خلوياً كبير نسبياً مقروناً كهربائياً. تمتلك الخلايا الوحيدة عمليات طويلة ويقيم البعض منهم اتصالات بالأوعية الدموية مشكلةً جزءاً من مانع الدم الدماغي. تمتد العمليات الأخرى وتغلف المشابك (وخاصةً المشابك المُولدة للحمض الأميني) كلوماتات (أي المشابك الاستثارية التي تحرر كلوماتات الناقل العصبي) كما تغلف الـــ Varicosities التي تُحرر منها نواقل عصبونية أخرى كالأمينات الأحادية. كما تغلف أيضاً الخلايا العصبية والعمليات العصبونية وسطح الدماغ بعمليات دبقية نجمية.

تشكل كتلة خلايا الدبق النجمية جزءاً بارزاً من حجم وعدد خلايا الدماغ الكلي (Peters, Palay, & Webster, 1991). قبل أكثر من 100 عام اقترح العالم Virchow أن لهذه

الخلايا دوراً مساعداً أيضياً وبنيوياً للخلايا العصبية. منذ ذلك الحين وحتى الــ 10 إلى 20 سنة الأخيرة تم الإبقاء على هذه الفكرة عن الخلايا النجمية بأنها خلايا مساعدة وسلبية بسيطة. أُعيرت الخلايا النجمية اهتماماً قليلاً جداً لعدة عقود، ربما بسبب غياب الوظيفة الفسيولوجية الواضحة في السلوك الفسيولوجي الكهربائي للجهاز العصبي. في الواقع، بينما كان من السهولة نسبياً تحديد والتعرف على الخلايا العصبية باستخدام تقنيات الفسيولوجية الكهربائية الناجم عن قدرتهم على تحرير كمونات فعل، فقد تكون الخلايا النجمية مزالة الاستقطاب ولا يمكن استنباط أي كمون فعل أو سلوك كهربائي نشيط آخر هام ذو دلالة.

تم في السنوات الأخيرة إظهار أنه بالإضافة إلى الوظائف المتعلقة بتوازن الدماغ (على سبيل المثال تزويد الطاقة للخلايا العصبية، والتحكم بتركيز الايونات والنواقل العصبونية في الوسط خارج الخلية، وتركيب وتحرير عوامل مُنميِّة عصبية)، فإن الخلايا النجمية تمتلك القدرة على مراقبة النشاط المشبكي والإحساس بتركيب الوسط خارج الخلية ووصل الدم، والقدرة على تجميع المعلومات المكتسبة والتأثير على النشاط العصبي والإرسال المشبكي بتنظيم التركيز خارج الخلية للنواقل العصبونية وبتحرير مواد تنشيطية عصبية مسماة نواقل دبقية (gliotramsmitters) (للمراجعة انظر Araque et al., 2001; Volterra, Marstretti & Haydon 2002).

سنقدم في هذا الفصل نظرة عامة عن معرفتنا الحالية لفسيولوجية خلايا الدبق وتأثيرها في الفسيولوجية العصبونية. كما سنناقش صلة هذه النتائج الجديدة بمفهوم الشبكات العصبونية الصنعية. سوف نقدم أولاً موجزاً عاماً عن وظيفة الشبكة العصبونية بتخليص المفاهيم الحيوية المشهورة والآليات الخلوية للوظيفة العصبونية والفسيولوجية المشبكية، ثم سنصف بشكل مختصر فسيولوجية خلية الدبق النجمية بدراسة إثارية خلية الدبق النجمية المعتمد على الكالسيوم Ca^{2+}، ووجود اتصال بين خلية عصبونية وخلية نجمية ونتائجه الفسيولوجية المتعلقة بالأداء الوظيفي للجهاز العصبي. أخيراً سوف نقترح إعادة تقييم نظرتنا الحالية للشبكات العصبونية الصنعية بافتراض ضرورة وسهولة دراسة شبكات الدبق العصبوني الصنعية.

الشبكات العصبونية الحيوية

سنقدم في الفقرات التالية بشكل مختصر بعض المفاهيم المفتاحية في الشبكات العصبونية الصنعية وبخاصة في الفسيولوجية العصبونية والفسيولوجية المشبكية. يمكن إن يجد القارئ المهتم وصف أوسع لهذه المواضيع في عدة كتب دراسية ممتازة. (على سبيل المثال Kandel, Schwantz, & Jessell, 1991، Nicholls, Martin & Wallace, 1992، Shepherd, 1994، Kuno, 1995)

يمكن أن يعتبر الجهاز العصبي كترتيب منظم من الخلايا المترابطة عبر مشابك، وتبرز وظائف الدماغ خارج التنظيم الديناميكي المعقد جداً للجهاز العصبي المركزي. يوجد في المستويات الأعلى لتنظيم الجهاز العصبي أنظمة وممرات. الممرات هي سلاسل ارتباطات عبر عدة مراكز خلايا عصبية - أي - مجموعات وظيفية وتشريحية من الخلايا العصبية. تكمن وظيفتها في نقل المعلومات من المحيط إلى الجهاز العصبي المركزي (كما هو الحال في الممر الحسي) أو من المركز إلى المحيط (كما هو الحال في الممر الحركي). الأنظمة المركزية – أو الأنظمة الموزعة – هي مجموعات من الارتباطات بين عدد من المراكز التي تسوي سويةً الوظائف الضرورية للسلوك المنسق للكائن الحي بالكامل. يوجد تعاقب تدريجي من الممرات التي تنفذ مهمات معينة من المعالجة الحسية والتحكم الحركي بالأنظمة المركزية التي تتعامل مع السمات العامة للسلوك.

المراكز العصبية - أو النوى - والدارات المحلية هي تجمعات من الخلايا العصبية وخلال الدبق المرتبطة معاً في شبكات، تستقبل هذه التجمعات المعلومات من مراكز أخرى، وتنفذ بعض عمليات معالجة معينة، وترسل الخرج إلى مراكز أخرى أو أعضاء فاعلة ومؤثرة (مثل العضلات أو الغدد). هذا المستوى من التنظيم يكافئ الترابطات البينية بين عناصر المعالجة في شبكات عصبونية صنعية.

البنية الهندسية ووظيفة الخلية العصبية

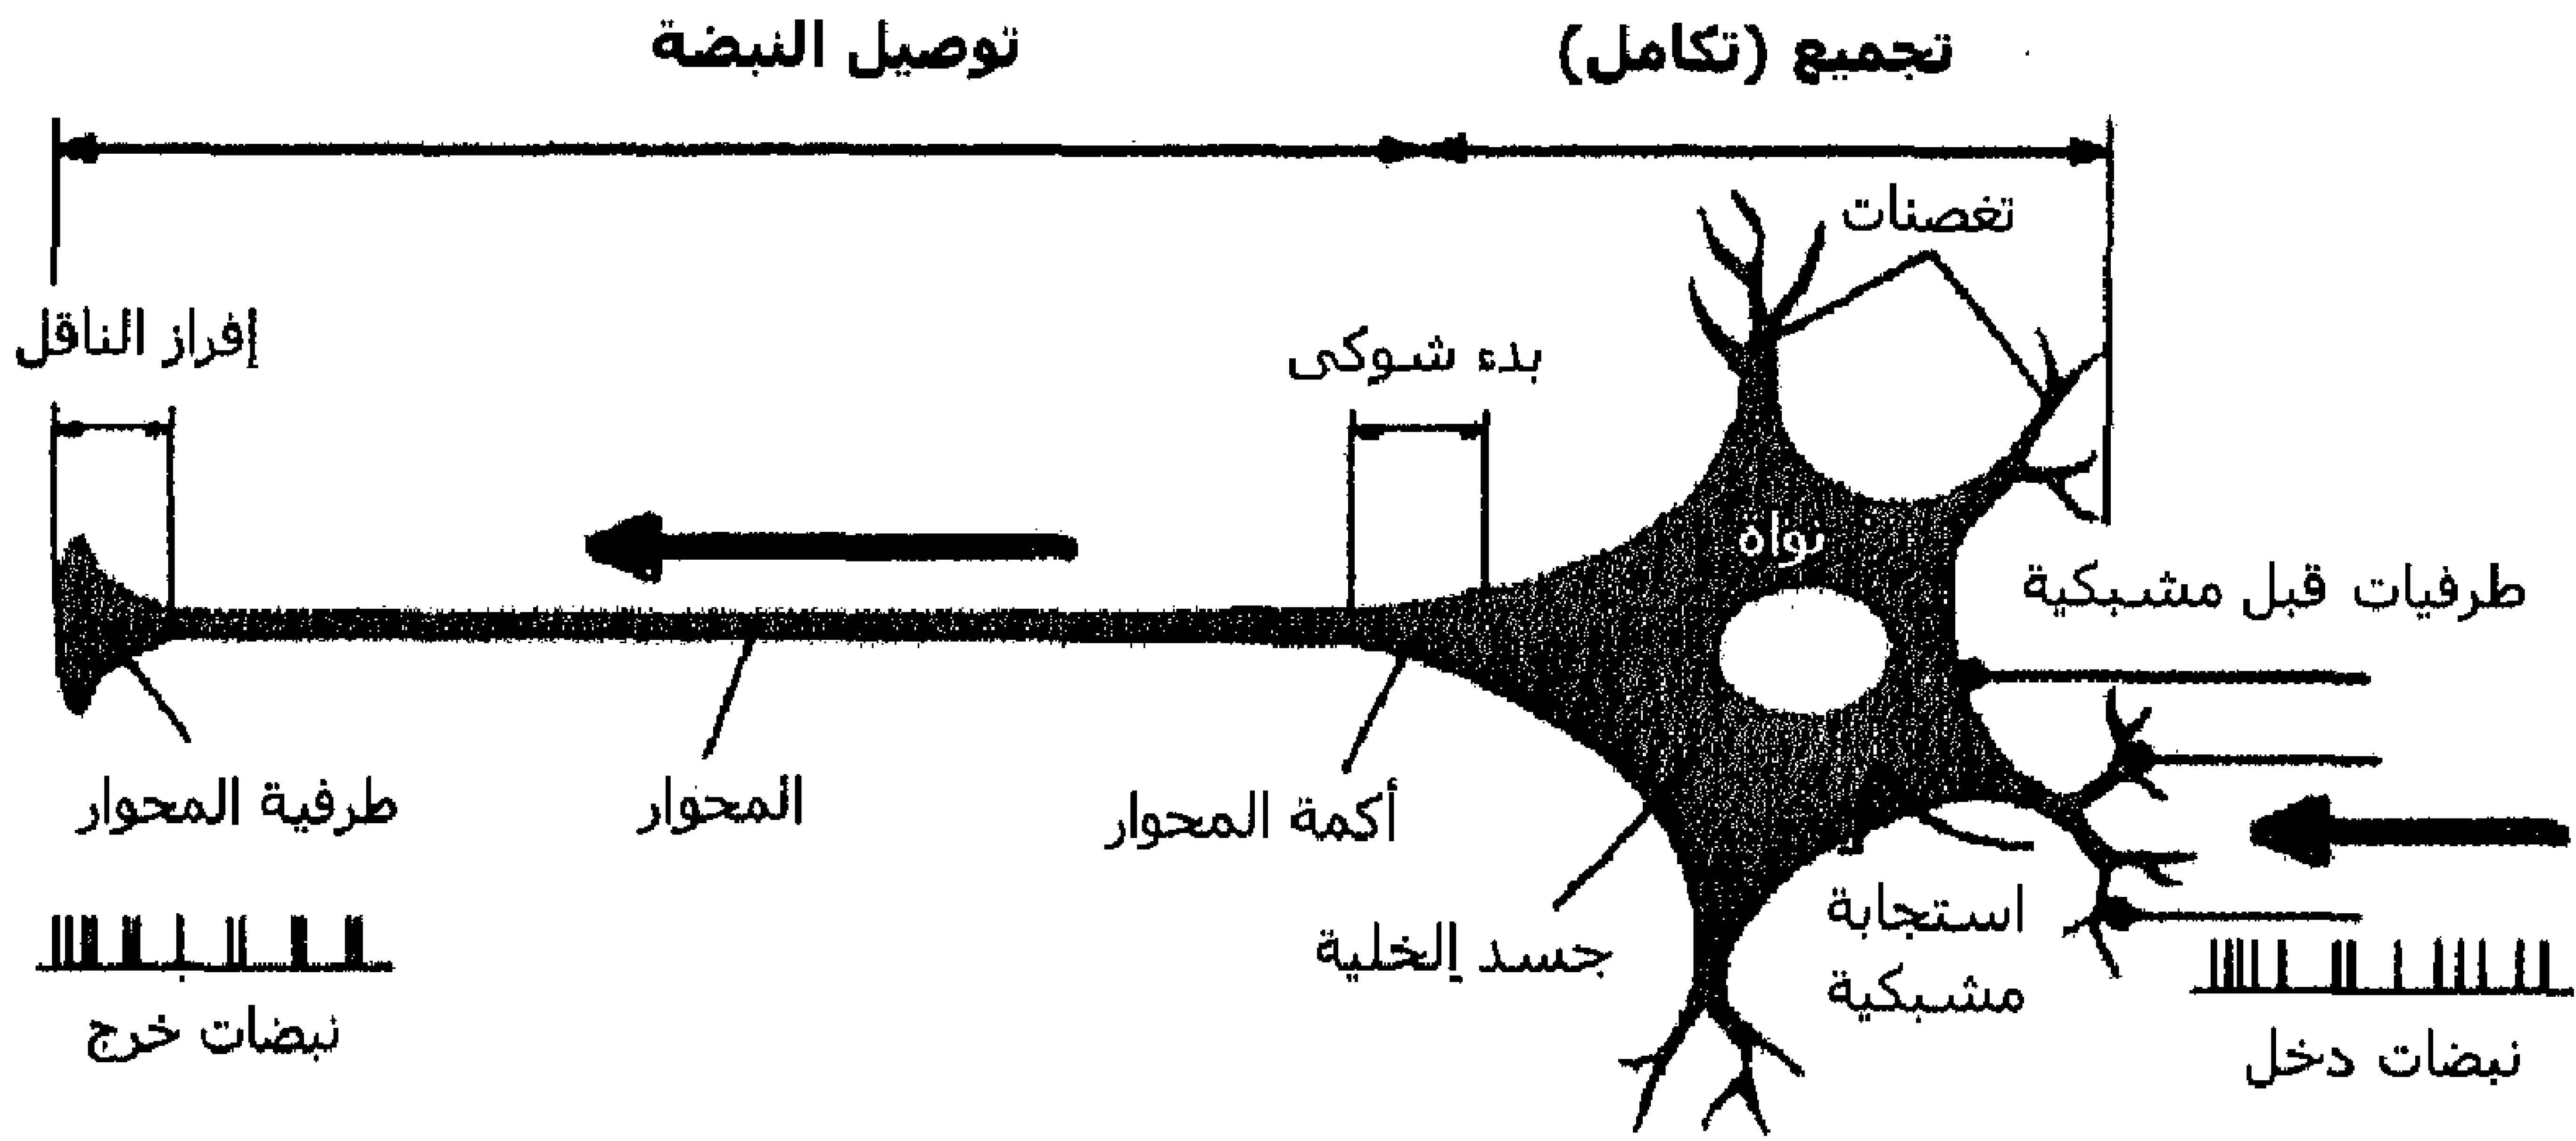
الخلية العصبية – التي قد تُعتبر الوحدة التشريحية الأساسية للجهاز العصبي – هي خلية متخصصة تستقبل الإشارات من خلايا أخرى عبر جسمها أو تغصناتها وتجمعها أو تكاملها (أي تطور الاستجابة، التي هي عبارة عن تابع للإشارات الداخلة المتعددة). وترسل إشارات الخرج إلى خلايا أخرى عبر محوارها. يبين (الشكل 1) هذه العناصر الأساسية.

مثل أي خلية أخرى، تكون الخلية العصبية مغلفة بغشاء دهني ثنائي الطبقة، ولها نواة مع مادة وراثية، كما لها التتمة العادية للجزئيات العضوية الخلوية كالمُتقّدره (فتيلة خيطية) mitochondrian، وشُبيكة بلازما داخلية endoplasmic reticulum وجسيمات حالّة Lysosomes ... وهلم جراً. على أية حال، تمتلك الخلايا العصبية علوماً تشكّلية خاصة (مورفوليات) اعتماداً على دورها وموقعها في الجهاز العصبي التي تتبع أو تسلك نموذجاً تشكّلياً مشابهاً: جسم خلية من حيث تمدد عدة فروع. عندما تنمو خلية عصبية ما فإن فرعاً واحداً فقط من هذه الفروع يصبح المحوار، بينما تصبح الفروع البقية تغصنات. في خلية عصبية نموذجية، كل منطقة لها وظائف إشارية متميزة.

1. الجسد (Soma): هو المركز الأيضي (التفاعل الحيوي) للخلية العصبية.
2. التغصنات (dendries) - الموافقة لمنطقة الاستقبال للخلية العصبية.
3. المحوار (axon): هو محور الاتصال العصبوني الذي ينقل المعلومات إلى خلايا بعيدة نسبياً.

4. طرفيات قبل مشبكية للمحوار التي هي عناصر إرسال الخلية العصبية. عبر هذه الطرفيات تتصل خلية عصبية ما وترسل المعلومات إلى سطوح استقبال خلية عصبية أخرى أو إلى عضلة أو إلى خلية غدة. تُعرف نقطة الاتصال هذه بالمشبك.

الشكل (1) *رسم تخطيطي لخلية عصبية نموذجية. تمثل جسد الخلية والتغصنات موقع استقبال الدخل والتكامل والتنسيق لإشارات المعلومات الواردة من طرفيات أعصاب قبل مشبكية. تنشر المعلومات من التغصنات وجسم الخلية إلى أكمة المحوار إذا كان مجموع الكمونات المشبكية الواصلة إلى أكمة المحوار أكبر من عتبة إزالة الاستقطاب لاضطراب كمونات فعل، عندها يحدث خرج كمون فعل واحد أو أكثر. المحوار مسؤول عن نقل كمون الفعل بيدل الـ CNS بين التعديل المطالي والتعديل الترددي. بينما يُنشر كمون الفعل بشكل مجدد بشكل كامل أو ناقص في المنطقة المحورية للعصب، فإن تردد كمونات الفعل المولدة في أكمة المحوار يكون متناسباً مع قيمة الاستجابة المشبكية للشبكة في ذلك الموقع. تُمثل المعلومات حول مجموع النشاط الكهربائي الواصلة إلى أكمة المحوار بتردد كمونات الفعل هذه.*



هناك نوعان رئيسان من الخلايا العصبية يمكن يُحدّدا من منظور اتصالات محاويرها. تمتلك الخلايا العصبية المسماة "إسقاطية" أو "رئيسية" أو "مُرحّلة" محاوير طويلة بشكل نموذجي، تصنع الاتصالات البعيدة. من الأمثلة على تلك الخلايا نذكر الخلايا العصبية الحسية والحركية التي تمتد إلى خارج الدماغ، والخلايا العصبية في الدماغ التي تصل إلى مراكز مختلفة من الجهاز العصبي. النوع الرئيسي الآخر من الخلايا العصبية له محوار أقصر بكثير ويتصل فقط بخلايا عصبية أخرى ضمن مركز ما. تدعى هذه الخلايا العصبية بالخلايا العصبية الداخلية أو الذاتية.

مثل أي خلية أخرى، تمتلك الخلايا العصبية ما يعرف بالكمون الغشائي، الذي هو فرق جهد كهربائي بين قسمي الخلية الداخلي والخارجي. يعتمد الكمون الغشائي هذا على الحقيقة التي

تقول بأنه يوجد عادة حوالي 10 مرات صوديوم أكثر في السائل خارج الخلية منه في السيتوبلازما، وحوالي 40 مرة بوتاسيوم أكثر في السيتوبلازما منه في السائل خارج الخلية. غشاء الخلية العصبية مزود بقنوات أيونية انتقائية نسبياً تسمح لبعض أيونات معينة بعبور الغشاء. في الظروف الساكنة تكون قنوات الصوديوم الأيونية مغلقة، وتمنع بالتالي أيونات الصوديوم من التسرب إلى الداخل. تكون بعض قنوات البوتاسيوم - على أية حال - مفتوحة ويُسمح للبوتاسيوم بالتسرب إلى خارج السيتوبلازما متبعاً ميل تركيزه. تصبح في هذه الحالة السيتوبلازما سلبيةً أكثر من السائل خارج الخلية، وتصبح في نهاية الأمر سلبية بما فيه الكفاية للبدء بجذب أيونات البوتاسيوم عكسياً إلى داخل الخلية. النقطة التي عندها يتعادل هذا الجذب مع البوتاسيوم المتبع لتركيزه تنتج في كمون الراحة الغشائي، الذي يكون قريباً من الكمون التوازني للتدرج الكهروكيميائي لأيونات البوتاسيوم والذي يكون حوالي 70 - ميلي فولط.

على خلاف العديد من الخلايا - على أية حال - تمتلك الخلايا العصبية أغشية قابلة للإثارة، لأن بعض القنوات الأيونية الانتقائية الموجودة في الغشاء هي ذات بوابات فلطية، أي أنها تفتح أو تغلق اعتماداً على الكمون الغشائي. تسبب الإشارات القادمة من تغصنات - منطقة الدخل لخلية عصبية - فتح قنوات الصوديوم. تعبر أيونات الصوديوم الغشاء متبعةً تدرج تركيزها ومزيلةً استقطاب الكمون الغشائي. ما إن يتم الوصول إلى عتبة إزالة استقطاب كافية حتى ينعكس فجأة فرق الكمون بين السيتوبلازم والسائل خارج الخلية. يدعى هذا الانعكاس غير المتوقع بكمون الفعل، ويمكن أن يُنشر على طور المحوار إلى طرفية المحوار يمثل كمون الفعل الركيزة الفيزيائية الحيوية التي تُرمّز المعلومات العصبونية.

الفسيولوجية المشبكية

المشبك هو وحدة الدخل - الخرج الأساسية لنقل المعلومات بين الخلايا العصبية. هناك نوعان من المشابك: كهربائية وكيمياوية. المشابك الكهربائية قادرة على نقل إشارات العصب بسرعة كبيرة وبشكل مباشر عبر فجوة صغيرة جداً بين خليتي أعصاب متصلتين عبر بنى هندسية خاصة تدعى بموصلات الفجوة. تملك موصلات الفجوة خصائص غشائية تزود ممراً للتبادل الخلوي لأيونات وجزيئات صغيرة بين الخلايا. يعتقد بأن اتصال موصلات الفجوة يُسهل تنسيق النشاط الخلوي في عدة عمليات فسيولوجية كتوازن النسيج، والتزامن العصبوني، والانقباض القلبي، وانقباض العضلة المنبسطة، والتطوير (Bennett et at, 1991). تُشكل قنوات مواصلات الفجوة من قبل أجزاء من بروتينات الغشاء وثيقة الصلة تدعى بالروابط connexins. تُشكل كل قناة بمجموعتين من ستة جزئيات رابطية تغطيان غشاء كل خلية اتصال مُشكلةً بذلك الرابطة connexon، وقناة موصلات الفجوة الوظيفية. عندما تُمرر الإشارة الكهربائية في المشابك

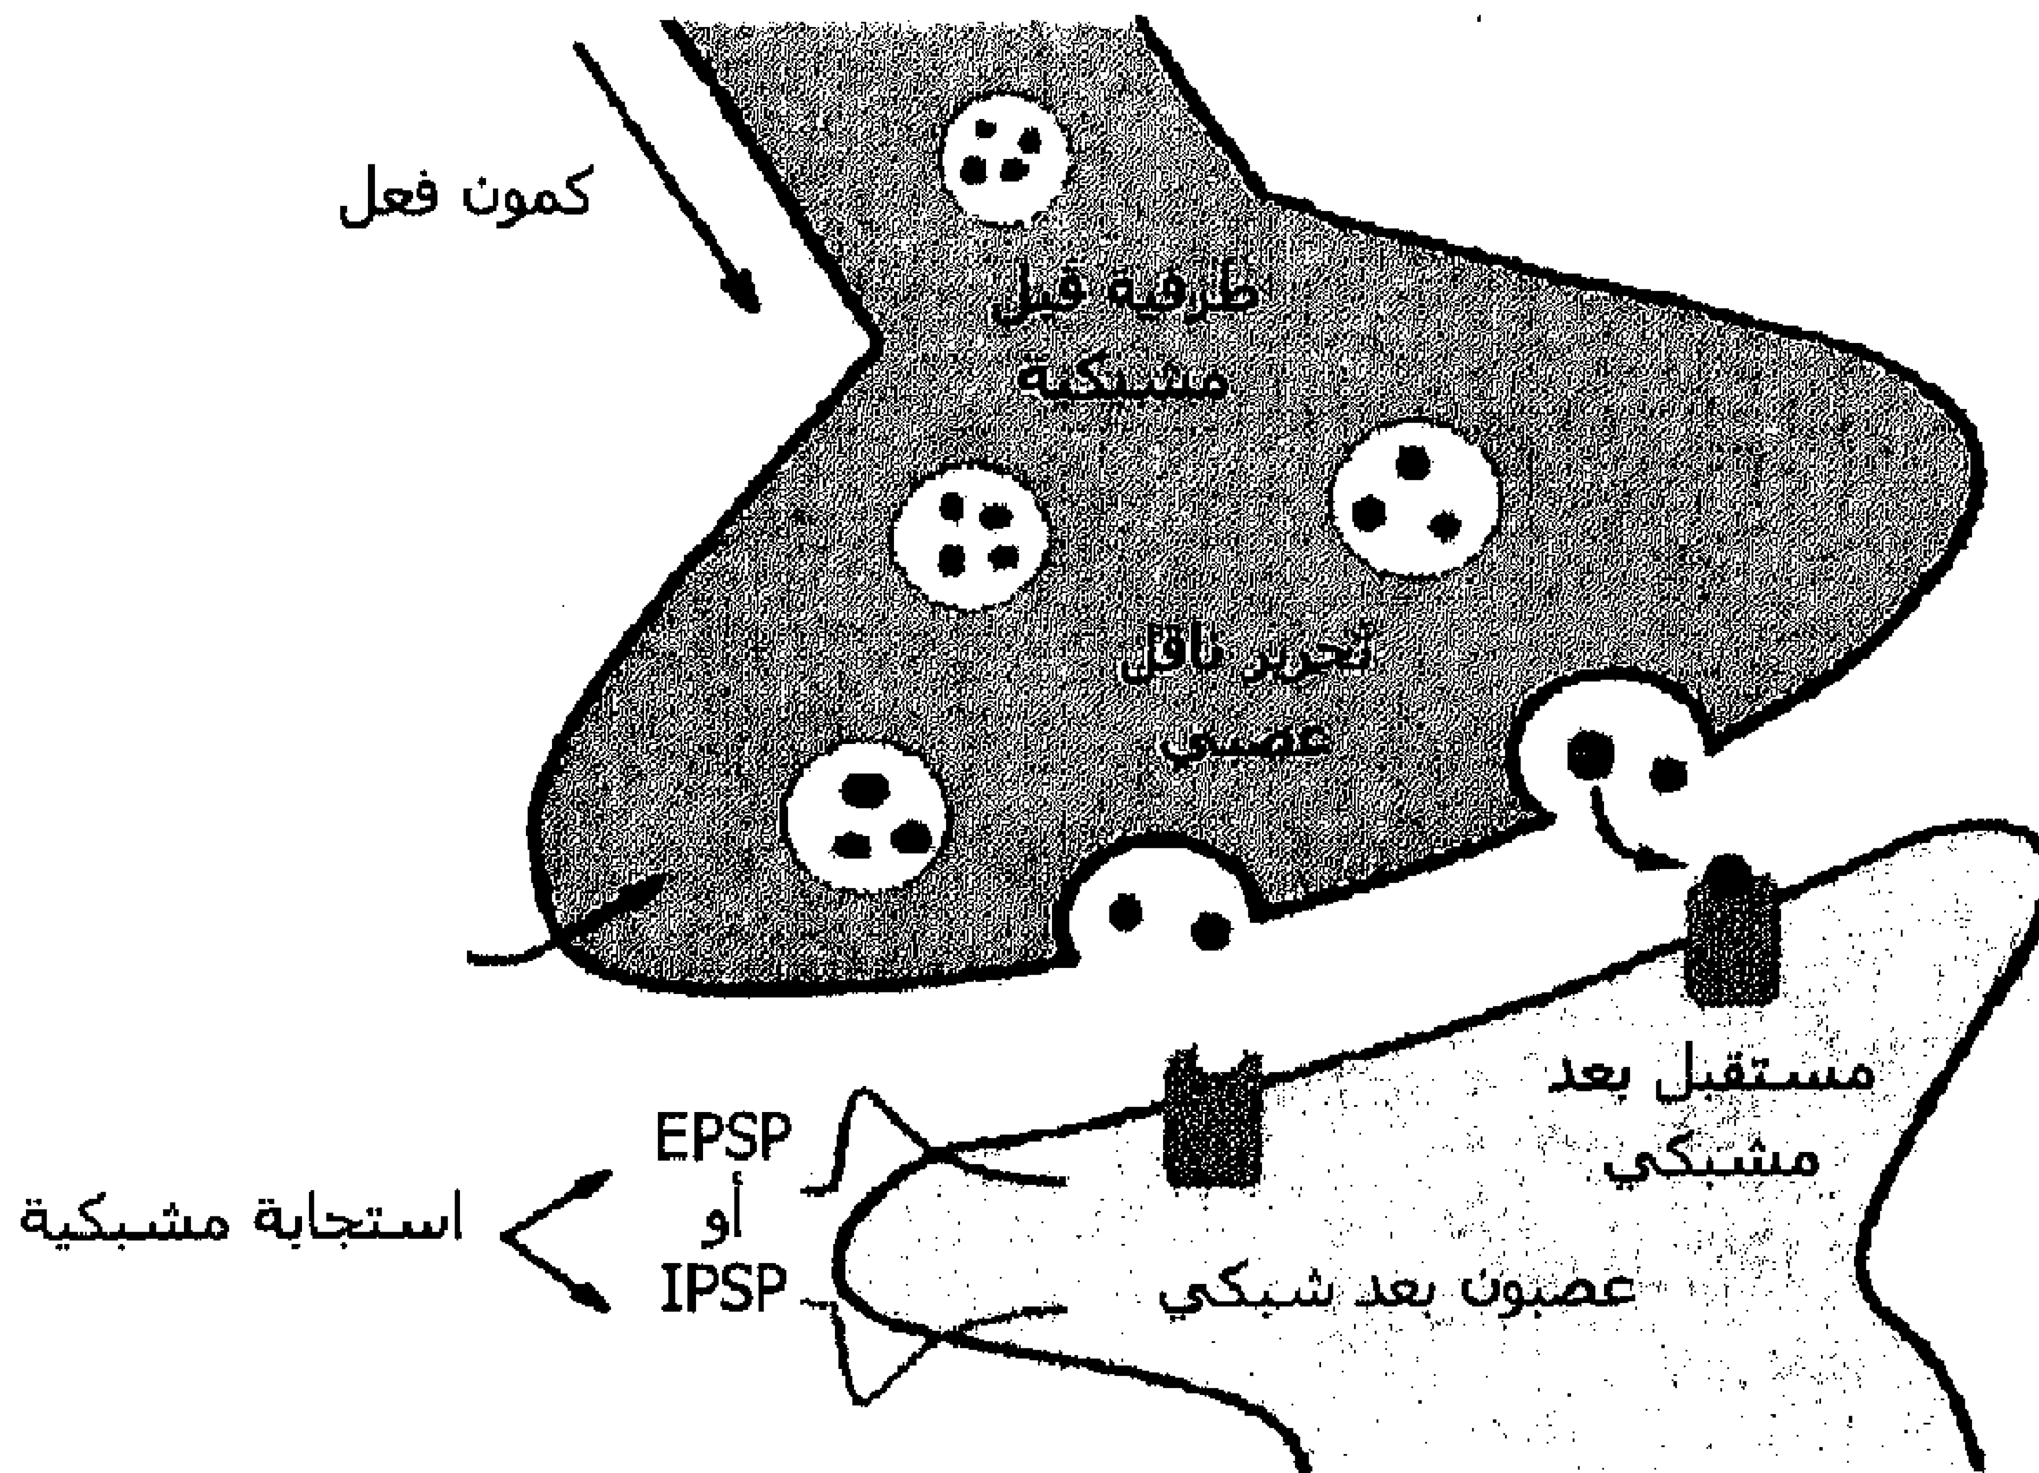
الكهربائية من خلية عصبية إلى أخرى، فإن إشارة الاتصال في المشابك الكيماوية تعتمد على مادة كيميائية تدعى بالناقل العصبي. على الرغم من أن المشابك الكهربائية مهمة جداً لوظيفة الجهاز العصبي، فإننا سوف نركز مناقشتنا في هذا الفصل على المشابك الكيماوية التي هي أكثر وفرةً ومدروسة جيداً.

عندما يصل كمون الفعل إلى طرفية المحوار لخلية عصبية قبل مشبكية، تُفتح قنوات ذات بوابات فولطية لـــ Ca^{2+} سامحةً بتدفق الكالسيوم Ca^{2+} إلى داخل الطرفية. تسبب الزيادة التالية لتركيز الكالسيوم داخل الخلية انصهار الفجوات أو الحويصلات التي تحتوي على نواقل عصبية. تنتشر هذه النواقل العصبية المحررة من طرفيات مشبكية عبر الشق (الفالق) المشبكي، وتُربط إلى مستقبلات على سطح الخلية العصبية بعد المشبكية. يؤدي هذا الربط إلى تغيرات بنفاذية الغشاء التي إما ستحفز أو ستثبط اضطرام الخلية العصبية الثانية (الشكل 2). يوجد كمية كبيرة من الجزئيات المختلفة التي قد تعمل كنواقل عصبية وهي مصنفة وفقاً لوظائفها الاستثارية أو التثبيطية. من جهة أخرى تُصنف مستقبلات النواقل العصبية وفقاً لآلية التأثير إلى: مستقبلات ذات وجود أيوني متعادل ionotropic، ومستقبلات ذات وجود أيضي متعادل metobotropic. يؤدي ربط النواقل العصبية إلى مستقبلات ذات وجود أيضي متعادل إلى تنشيط بروتينات محددة وإنتاج مراسيل ثانوية خلوية، يمكن أن تؤثر أخيراً على سلوك الخلية العصبية. تدعى المستقبلات ذات الوجود الأيوني متعادل أيضاً بالقنوات ذات البوابات الربطية (ذرة أو مجموعة ذرات أو أيونات تحيط بالذرة المركزية)، لأنها بروتينات نافذة للغشاء تشكل قنوات أيونية خاضعة لتغيرات شكلية على ربط النواقل العصبية، بمعنى أن هذه القنوات الأيونية تُفتح من قبل نواقل عصبية. هذه القنوات ذات الوجود الأيوني المتعادل هي محددة في نوع الايونات التي تسمح بالمرور عبرها. إذا سمح مستقبل ما لأيونات سالبة - كالكلور Cl^- - بالتدفق إلى داخل السيتوبلازما، فعندئذ سيملك هذا المستقبل تأثيراً تثبيطياً، بحيث يحرك الكمون الغشائي بعيداً عن عتبة اضطرام كمونات الفعل. من جهة أخرى، إذا سمح مستقبل ما لأيون موجب بالدخول إلى السيتوبلازما، فيملك عندئذ تأثيراً استثارياً جيداً يزيل استقطاب الكمون الغشائي المحلي محضراً إياه أقرب إلى عتبة كمون الفعل.

يتضمن تجميع معلومات مشبكية من قبل خلايا عصبية تآثرات مُعقدة بين تيارات أيونية وتشكيلات مشبكية: تؤدي إلى السلوك العام للخلية العصبية. في مشابك فردية، يزيل الجهد بعد المشبكي الاستثاري استقطاب الكمون الغشائي. وعلى العكس يفرط جهد بعد مشبكي تثبيطي في استقطاب الكمون الغشائي (الشكل 2). هذه التأثيرات غير منفصلة كإشارات في دارة كهربائية أو أعداد في معادلة. بشكل مشابه للسائل خارج الخلية، يكون القسم الداخلي للخلية العصبية بيئة مستمرة تنشر الأيونات ضمنها. عندما يوجد EPSP في تغصن، تنتشر الايونات

الموجبة ليس فقط داخل المنطقة المحلية للسيتوبلازما، بل أيضاً بعيداً عنها بكافة الاتجاهات (وبطريقة مماثلة من أجل IPSPs). يمكن أن يؤثر هذا التدفق الأيوني على مناطق أخرى. يؤدي تنشيط مشبك استثاري في تغصن إلى حدوث تيار داخلي (نحو الداخل) يظهر استقطاباً وينتشر على طول التغصن الأقرب للمحوار، وفي جسم الخلية، وفي أكمة المحوار (الجزء الأولي للمحوار حيث يُولّد عادة كمون الفعل).

الشكل (2) *يحدث الاتصال بين الخلايا العصبية بواسطة بنية هندسية خاصة تدعى بالمشبك. قد تولّد أو تثبط كمونات فعل في العصبون قبل المشبكي كمونات فعل في العصبون بعد المشبكي عن طريق كمونات مشبكية. يكون الفالج بين العصبونات مُجّسراً إما كهربائياً (مشبك كهربائي) أو كيماوياً (مشبك كيميائي) بواسطة نواقل عصبية. يوجد في الطرف الأقصى لليف العصبي قنوات كالسيوم ذات بوابات فولطية سوية مع قنوات بوتاسيوم وصوديوم ذات بوابات فولطية. تسبب كمونات فعل في طرفيات العصب تدفق C_a^{2+} (أيونات الكالسيوم) ناجم عن فتح قنوات الكالسيوم. تكون الزيادة الحاصلة للكالسيوم خارج الخلية مسؤولة عن تحرير نواقل عصبية تنقل المعلومات إلى العصبون بعد المشبكي خلال الإرسال المشبكي.*



على أية حال،عندما يكون مشبك تثبيطي واقع بين المشبك الاستثاري وجسم الخلية مُنشطاً، فإن التيار الخارجي (نحو الخارج) الناتج يفضي إلى زيادة مفرطة في استقطاب الغشاء. وعندنا يحدث ذلك مصاحباً بـــ EPSP، فإنه يُخفض الاستقطاب المثار بـــ IPSP لجسم الخلية ولأكمة المحوار. وبالتالي تتنافس الـــ EPSPs وIPSPs المتعارضة من أجل التحكم بالكمون الغشائي في نمط لا خطي. قد يؤدي تكامل كافة المشابك الاستثارية والتثبيطية - أي الجمع اللاخطي لها - أخيراً إلى التوليد النهائي لكمون فعل ينتشر على طول المحوار.

في المعدل، كل واحد من مئات الملايين من الخلايا العصبية المقدّرة أن تكون موجودة في دماغ جرذ تستقبل حوالي 6000 اتصال مشبكي، وقد تكون استثارية أو تثبيطية. لذا، يُطبق المستوى التالي لتعضي الجهاز العصبي على التعضي المشبكي الذي يتضمن أشكالاً لمشابك مترابطة. يُشكل الشكل الأبسط من تلك الأشكال بواسطة مشبكين واقعين بالقرب من بعضهما البعض وموجهين بنفس الاتجاه. يمكن أن يُعرف مشبك بسيط بأنه المشبك الذي تكون فيه طرفية محوارية لخلية عصبية مقرونة مع التغصن لخلية عصبية أخرى (محوارية تغصنية axodentritic) أو مع جسم خليتها (محوارية جسمية axosomatic). على أية حال، معظم أجزاء الجهاز متغصنة في أشكال أكثر تعقيداً. على سبيل المثال، المشابك التغصنية - التغصنية (dentrodentritic) هي تلك التي يرسل فيها التغصن إشارة أحادية الاتجاه إلى تغصن آخر. المشابك المتبادلة هي تلك التي يكون فيها إرسال الإشارة ثنائي الاتجاه لمشابك تغصنية - تغصنية. تُشكل المشابك المحوارية - المحوارية (axoaxomic) عندما تتصل الطرفية المحوارية لخلية عصبية مع الجزء الأولي أو محوار خلية عصبية بعد مشبكية. المشابك المتسلسلة هي سلاسل إشارات أحادية الاتجاه لأكثر من عمليتين. الأمثلة على ذلك هي التسلسلات المحوارية - التغصنية - التغصنية (axodentrodentritic) التي يرسل فيها المحوار إشارة إلى تغصن، ثم يرسل إشارة إلى تغصن آخر، والتسلسلات المحوارية - المحوارية - التغصنية (axoaxodendritic) التي يرسل فيها محوار إشارة إلى محوار آخر الذي يرسل إشارة تغصن. من المفترض أن تعمل هذه الترتيبات المعقدة للمشابك - التي تشكل مستوٍ مداري ميكروي للتعضي - بطريقة موحدة من أجل معالجة المعلومات (kuno, 1995, kandel et at., 2000).

في الخلاصة، فإن الجهاز العصبي يُبنى بدرجة عالية من التعقيد الوظيفي والمورفولوجي الموجود في كافة المستويات المتعاقبة للتعضي من المستوي الجزيئي (على سبيل المثال توزيع وتعبير مستقبل معين) إلى المستوي الخلوي (على سبيل المثال المواصفات العصبونية المورفولوجية ومظهرات مورثات فسيولوجية للمشابك)، والمستويات فوق الخلوية (على سبيل المثال، الأداء الوظيفي للمدارات الميكروية واتصالات النوى).

شبكات الدبق العصبوني

من المعروف منذ فترة طويلة بأن الخلايا العصبية ترسل إشارات إلى بعضها البعض بواسطة أنواع مختلفة من مواد ناقلة. كشفت المعطيات الأخيرة بأنه من المحتمل أن يُحدّد نشاط الدبق بنشاط عصبوني، وأن خلايا الدبق تمتلك القدرة لإرسال إشارة ليس فقط إلى بعضها البعض، وإنما أيضاً عكسياً إلى خلايا عصبية. الخلايا النجمية هي أكثر الخلايا وفرةً في الدماغ مشكلةً أكثر من 50% من العدد الكلي للخلايا في القشرة المخية (Peters et at. 1991). عددها النسبي مرتفع بشكل خاص

في البشر وفي الثدييات الأخرى المتطورة جداً. وهي تُعرّف كخلايا نجمية الشكل تمتد عملياتها إلى البواسير العصبونية المحيطية (Neuropil)، وهي مقرونة على نطاق واسع في شبكة خلوية. كما ترتبط أيضاً بحميمية بالخلايا العصبية بنيوياً ووظيفياً مشيرةً بذلك إلى الأدوار الهامة لخلايا الدبق النجمية في وظيفة الدماغ. في الواقع، هي تشترك في التوجيه العصبوني خلال التطوير: (Hatten & Mason, 1990، ULLian, Sapperstein, Chirstopherson & Barres, 2001)، والاصطفاء العصبوني: (Banker, 1980، Pfrieger & Barres, 1995، Tascopoulos & Magistett; 1996)، وفي التفاضل: (Takeshima, Shimodo، Sauve & Commissiong, 1994)، والتوجيه العصبوني: (Bastiani & Goodman, 1986، Kuwada; Rakic, 1990)، والنمو العصبوني (على سبيل المثال Johnson et at. 1989، Le Roux & Reh, 1994، Noble et at. 1984)، وتكوين المشابك: (Ullian et at, 2001، Slezak & Pfrieger, 2003، Ullian, Christopherson & Barres, 2004)، والتحكم بالتركيز المحلي للأيونات خارج الخلية: (Largo, Cuevas, Somjen, Martin del Rio, & Herreras, 1996)، (orkand, Nicholls & Kuffler, 1996، وفي النواقل العصبية: (Szathowski, Barbour &Attwell, 1990، Mennerik & Zorumsk, 1994، Verndakis, 1996، Largo etaL., 1996، Walz, 1989).

مورفولوجياً، الخلايا النجمية مرتبطة مباشرة بالخلايا العصبية، ويمكنها تغليف طرفيات مشبكية وإقامة ارتباط بيني شامل بخلايا البطانة (الغشائية) من الأوعية الشعرية، كما أنها مرتبطة عبر موصلات فجوية (Ventura & Harris, 1999). العدد من القنوات الأيونية الموجودة في الخلايا العصبية (القنوات الفلطية، القنوات الرباطية، والقنوات المُنشطة ميكانيكياً هي أيضاً موجودة في خلايا نجمية (Barres, Chun, & Cores, 1990, Sontheimer, 1994). على الرغم من أن الدلالة والأهمية الوظيفية لهذه القنوات الأيونية لم تفهم بالكامل، تشير المعطيات إلى أن لديها وظائف هامة. على سبيل المثال، تشكل القنوات الأيونية شرطاً لازماً من أجل تنظيم المحلول خارج الخلية لخلية دبقية، ومن أجل الاستجابة للنشاط المشبكي ومن أجل الاتصالات الخلوية (انظر المقطع القادم).

دعم الخلايا النجمية ومراقبة النشاط العصبوني

لدى العديد من الخلايا النجمية عمليات تصل الأوعية الدموية مع (أطراف – قدم) خاصتهم مشكلةً جزءاً من مانع الدم الدماغي مع البطانة الشعرية.(Nedergaard, Ranson, & Goldman, 2003). تمتد العمليات الأخرى إلى أجسام الخلايا العصبية، وتعمل الخلايا النجمية بذلك كوصلة بين الخلايا العصبية وتوزيع الدم (الشكل 3).

تصل عمليات الخلايا النجمية إلى الخلايا الخارجية رابطةً إياها مع النظام البطني المخي، بينما تمتد العمليات الأخرى إلى سطح الدماغ لتشكل التوسعات والتضخمات التي تشكل الغشاء المحدد

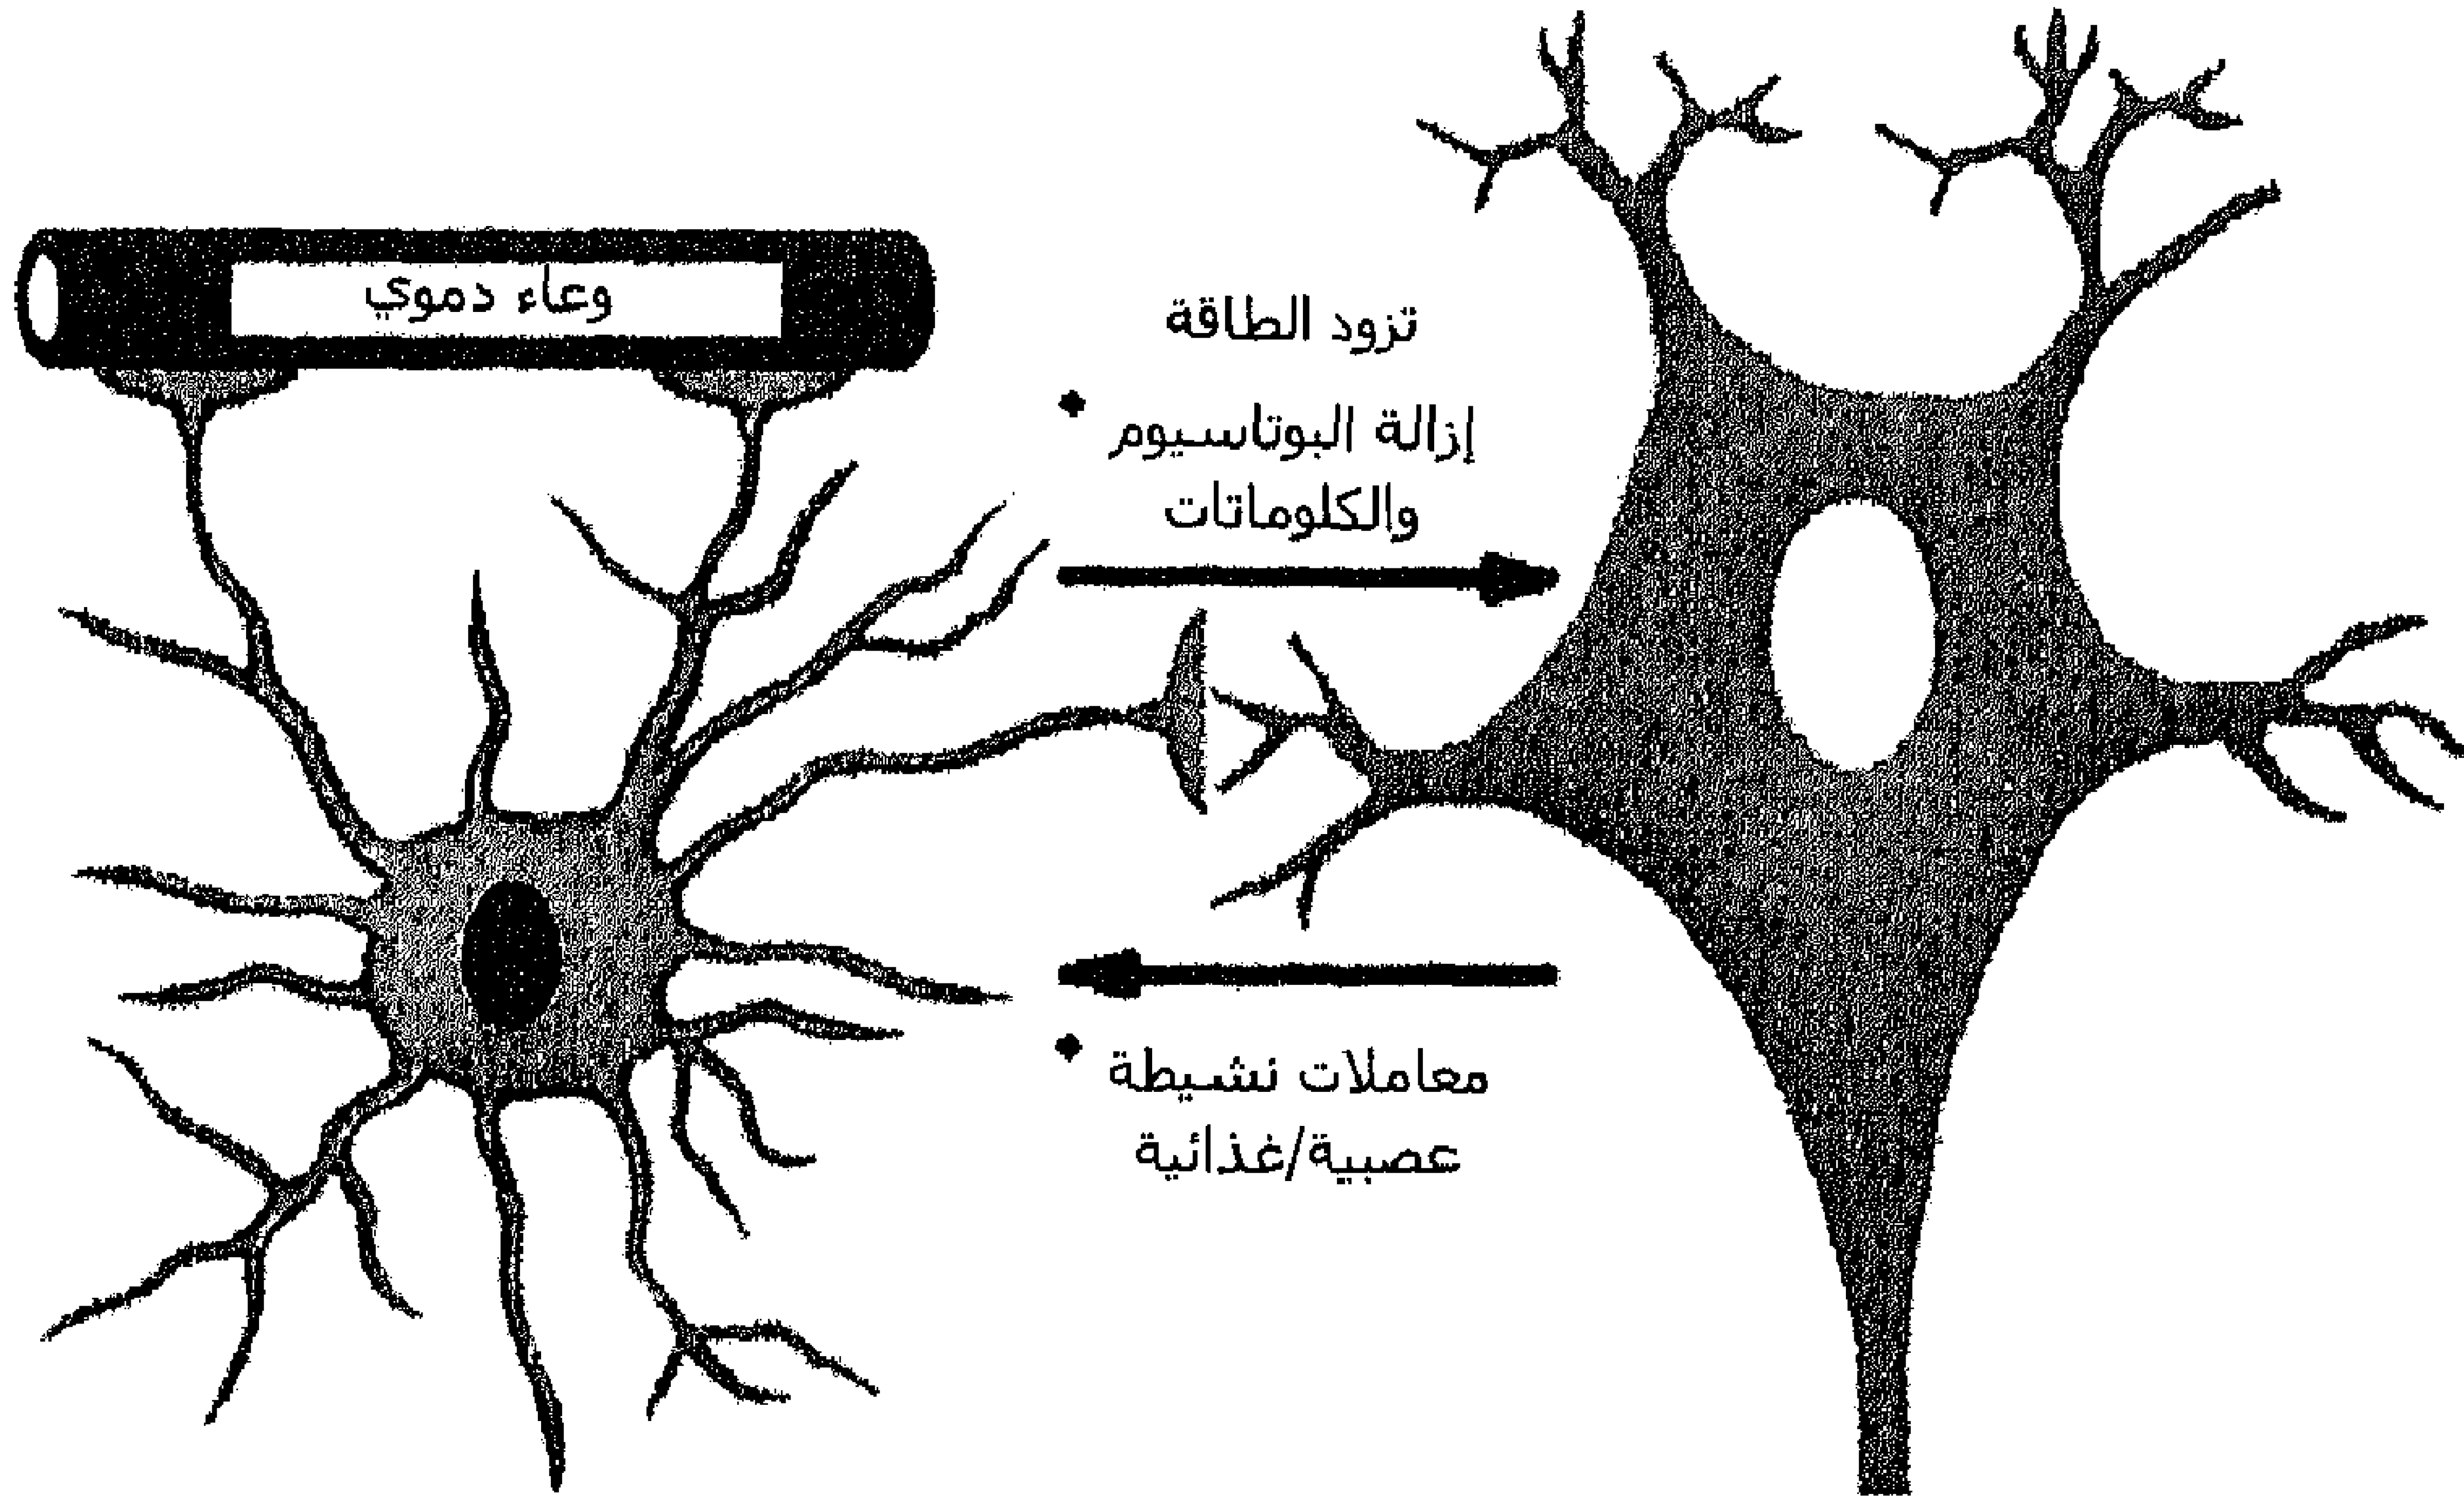
للدبق (Peters et at, 1991). علاوة على ذلك، تقترب عمليات أخرى مباشرة من المناطق المشبكية وتعمل على تغليف النواتج (الشقوق) المشبكية (Ventura & Harris, 1999). نظراً لحقيقة أن الخلايا النجمية تعبّر عن تنوع القنوات الأيونية وعدداً كبيراً من مستقبلات المرسلات العصبونية وعدة تحريرات نشيطة وآليات امتصاص لمواد النشاط العصبوني، فإن هذا التقارب المباشر للخلايا النجمية من المشابك، يمكّنها من الاتصال بالخلايا العصبية.

أحد الأدوار الأولى المُميّزة للخلايا النجمية هو دعم التفاعل الحيوي للخلايا العصبية. يؤخذ الغلوكوز إلى داخل خلية الدبق النجمية من الدم، ويُحوّل إلى غليلوجين (نشا حيواني)، ويخزن. عندما يكون مطلوباً – وخصوصاً عند الطلب أثناء النشاط العصبوني – تطلق الخلايا النجمية اللنباز (Lactate) والمركبات الأخرى الغنية بالطاقة كي تستعمل كوقود للتفاعل الحيوي للخلايا العصبية (الشكل 3). يعدّ التفاعل خلية عصبية – خلية دبق أساسياً للتفاعل الحيوي الطاقي للدماغ. تشير البيانات المُجمعة إلى أن التفاعل الطاقي المخي هو تحت تنظيم تفصيلي لتأثير نواقل عصبونية على خلايا الدبق تلك: (Hamprednt & Dringen, 1995، Magistretti; et at. 1994، Tsacopouos & Magrstretti, 1996، Bernadinelli, Magistretti, & Chatton, 2004، Pellerin & Magistretti, 2004).

يخفض ويُعدل التنشيط الأيضي لخلايا الدبق الإرسال المشبكي، وتمتلك الخلايا النجمية تأثيراً وقائياً عصبونياً مثبتاً تحت ظروف إجهاد تفاعل حيوي (Takuma, baba, & Matsuda, 2004)، ومن المحتمل أن تحملها الكبير للإجهاد الخلوي كنقص الأكسجة (نقص الأكسجين و في الخلايا الجسم) hypoxia ونقص الغليسريك hypoglycemia هو فريد بين الخلايا الدماغية. تستخدم – بالتالي – كمية كبيرة من الطاقة المولدة ضمن الخلية النجمية نفسها لتشغل مضخات الغشاء الضرورية لوظائف الدماغ الأساسية. المحلول المنظم الأيوني، وامتصاص الحمض الأميني كلوماتات، وتنظيم حجم الخلية هي جميعها أوليات التفاعل الحيوي الأعلى. كما تلعب الحالة الطاقية أيضاً دوراً في تنظيم الاتصال الخلوي (Hertz, & Peng, 1992، Swanson, & choi, 1993، Tsacopoulos & Magistretti, 1996). الحمض الأميني كلوماتات (الدبق) هو الناقل العصبوني الاستثاري الأكثر وفرةً في الجهاز العصبي المركزي. يُنهى الإرسال المشبكي لتوليد الحمض الأميني بشكل كبير بانجذاب عالٍ – الذي هو نقل معتمد على الصوديوم للكلومات من الشق المشبكي (على سبيل المثال، Bergles, Diamond, & Jahr, 1999).

علاوة على ذلك، تحافظ نواقل الدبق على تركيزه خارج الخلية في مستويات منخفضة، والذي يكون حاسماً بسبب التأثيرات الاستثارية المشهورة للمستويات العالية لمادة الدبق المحيطية (Choi & Rothman, 1990) (الشكل 3).

الشكل (3) دعم الخلايا النجمية ومراقبة النشاط العصبوني. إن الخلايا النجمية التي تكون في موقع مفتاحي بين الأوعية الشعرية والخلايا العصبية تأخذ الغلوكوز من الدم وتحوّله إلى غليلوجين (نشا حيواني)، يستخدم كدعم طاقي مخزن. اعتماداً على الطلب، فإن المواد الأيضية المثارة بأنزيم معين - مثل الإلبان Lactate والحمض الأميني كلوماتات - تُصدّر إلى خلايا عصبية. من جهة أخرى تتحكم الخلايا النجمية بالمستويات خارج الخلية للأيونات والمواد النشيطة العصبية مثل الكلوماتات.



تمتلك كلٌ من خلايا الدبق النجمية والخلايا العصبية حوامل (نواقل) امتصاص دبق متشابهة – بالرغم من أنها غير متماثلة – في أغشية البلازما الخاصة بها. مع ذلك، فإن قدرة الخلايا العصبية على رفع مادة الدبق أقل من قدرة خلية الدبق، بالرغم من أن التركيب البنيوي للشق المشبكي قد يفضل إزالة عصبونية لمادة الدبق بعد تحريرها من المنطقة قبل المشبكية. مع ذلك، فإن قدرة امتصاص الدبق من قبل خلية دبق نجمية تعتبر كافية لتؤخذ بالحسبان من أجل كافة الدبق المُحرر من قبل خلايا عصبية. بالرغم من أن المساهمة النسبية للخلايا العصبية وخلايا الدبق لامتصاص الدبق قد تتفاوت بين مناطق مختلفة من الدماغ (Schousboe, 1981; Bergles et at., 1999).

الاتصال الخلوي البيني لخلية نجمية

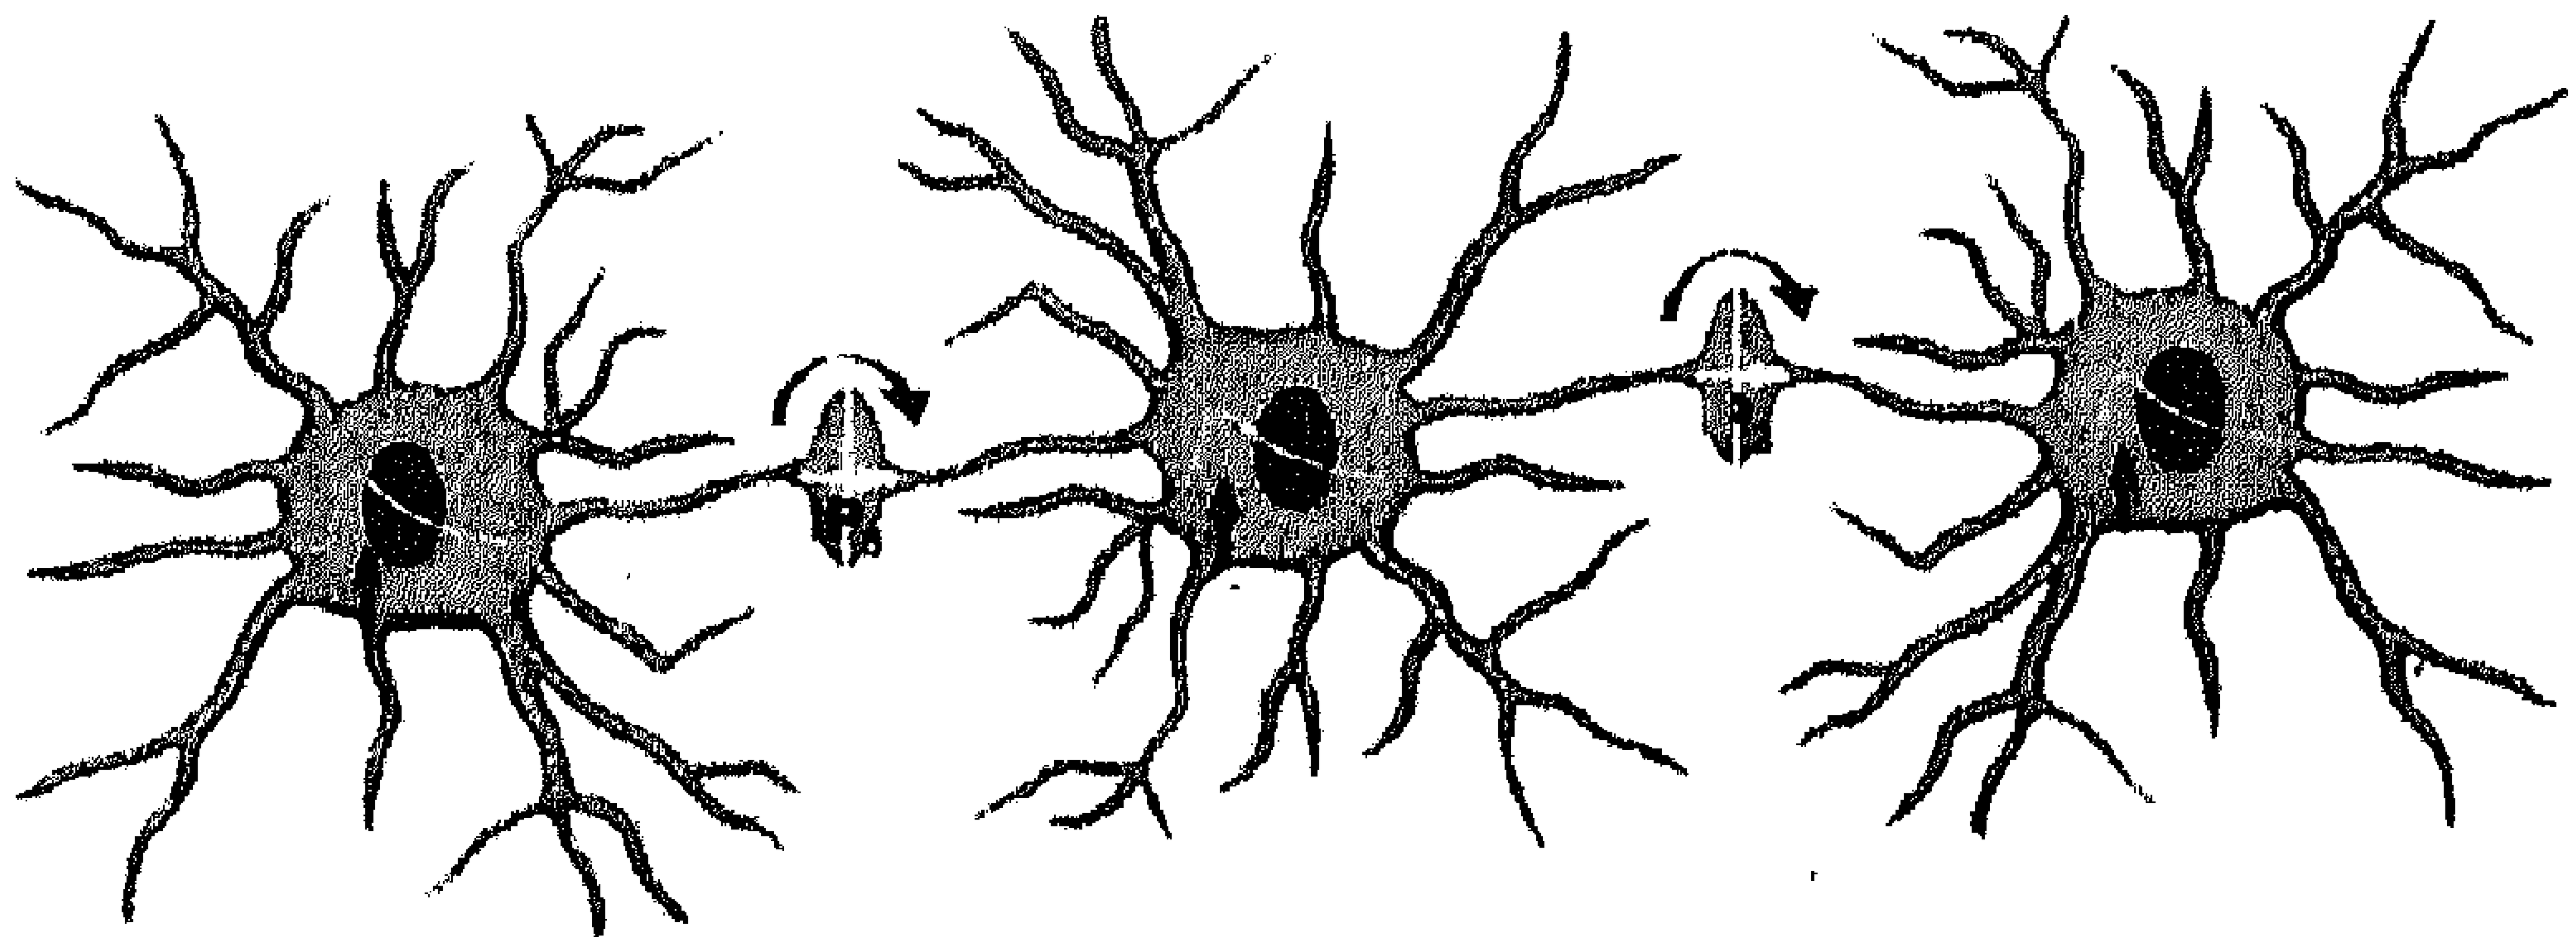
أصبح من الواضح مؤخراً، بأن بعض أنواع الخلايا ، بما في ذلك خلايا الدبق النجمية – تتصل خلوياً بواسطة تدفقات كالسيوم زمانية ومكانية (Cornell-Bell, Finkbeiner Cooper & Smith 1990، Charles & Giaume, 2002). يمكن أن تبدأ أمواج Ca^{2+} الخلوية في خلايا نجمية وخلايا غشائية بمحفزات ميكانيكية أو كيماوية أو كهربائية. يؤدي التحفيز إلى زيادة في تركيز Ca^{2+} الخلوي

الذي يُنشر من خلية إلى خلية (الشكل 4) (Verkhartsky, Solovyeva, & Toescu, 2002، Charles, Giaume, 2002) قد تسبب المحفزات المختلفة، متضمنةً عدة نواقل عصبونية، زيادات Ca^{2+} خلوية، يمكن أن تنتشر كأمواج Ca^{2+} بين خلايا نجمية في الخلايا المثقفة بالإضافة إلى الخلايا العصبونية النموذجية وشرائح الدماغ الذكية (Dani, Chernjavsky, & Smith, 1992، Cornell-Bell et at. 1990، Schipke, Boucsein, Ohlemeyer, Kirchhoff, & Kettenmann, 2002، Sul, Orosz, Givens, & Haydon, 2004) يمكن أن تمتد أمواج Ca^{2+} تلك للخلية النجمية إلى مسافات بعيدة نسبياً (أقل من 500 ميكرومتر) وبسرعة منخفضة نسبياً (حوالي 14ميكرومتر/ثا) (Schipke et at., 2002).

لقد أصبحت الآليات الخلوية الواقعة تحت انتشار أمواج Ca^{2+} لخلية نجمية بؤرة اهتمام للعديد من الدراسات بسبب وظائفها الهامة المتحملة كشكل مبتكر من الاتصال الخلوي في الجهاز العصبي. تعبر الخلايا النجمية عن مجال واسع من مستقبلات النواقل العصبونية والعديد منها ذو وجود أيضي متعادل metabotropic. يثير تنشيط هذه المستقبلات ارتفاعات Ca^{2+} الخلوية، التي تنتج من إطلاق Ca^{2+} من المخازن الخلوية، التي تُنشط بارتفاعات المرسال الثانوي – الفوسفات الثلاثي (أو ملح حامض الفسفوريك) IP3.

يُولّد هذا المرسال كنتيجة لنشاط ليباز (مميزة حالة للدهن) الفوسفات C (Phospholipas C)، الذي يُنشط بدوره من قبل مستقبلات محددة ذات وجود أيضي متعادل مقرونة ببروتين C. اعتُقد في البداية أن أمواج الكالسيوم تنتشر كنتيجة لانتشار IP3 عبر الموصلات الفجوية بين الخلايا النجمية (Senyd, Charles, & Sandreson, 1994) (الشكل 4). وقد أشارت الدراسات اللاحقة بأنه بالإضافة إلى انتشار IP3، يمكن أن تتواجد آليات أخرى لانتشار أمواج Ca^{2+} لخلية نجمية، واقتُرح تضمين مكون خارج الخلية في الموجة Ca^{2+} الخلوية (Hassinger, Guthrie, Atkinson، Bennett, & Kater, 1996)، لأنه يمكن لأمواج Ca^{2+} أن تعبر بشكل متكرر بين خلايا غير متصلة طالما أن الفجوة بينهما لا تزيد عن حوالي 120 ميكرومتر. من المحتمل أن يكون المكون خارج الخلية هو ATP الذي يمكن أن يُطلق من خلايا نجمية. يظهر إطلاق ATP بأنه مكون هام جداً لإرسال إشارة Ca^{2+} لمسافة بعيدة، بينما يمكن أن يتم إرسال الإشارة إلى مسافة أقصر عن طريق اقتران خلوي عبر الموصلات الفجوية (الشكل 4). (Cortrina et at., 1998، Guthrie et at., 1999، Charles & Giaume, 200) وهكذا، تشير معرفتنا الحالية إلى أنه يمكن أن تروّج خلايا نجمية لإرسال إشارة بعيدة المسافة من شبكة عصبونية إلى أخرى، وأن هذا الاتصال يمكن أن يحدث طالما أن هناك خلايا نجمية متصلة، حتى وإن لم تكن الشبكتان العصبونيتان مقرونتين عبر مشابك.

الشكل (4) *تشكل الخلايا النجمية مدمجاً خلوياً يظهر شكلاً من الإثارة يعتمد على تغيرات Ca^{2+} الخلوية البينية. يمكن أن تنتشر تغيرات Ca^{2+} هذه إلى الخلايا النجمية المجاورة مشكلة موجة من Ca^{2+} المرتفع. تسوى أمواج Ca^{2+} لخلية نجمية بشكل رئيسي بتحرير ATP التي تؤثر على مستقبلات صافية الطاقة في الخلايا النجمية المجاورة، وتحفز إنتاج IP3 الذي يزيد Ca^{2+} الخلوية عبر تنشيط مخازن Ca^{2+} الخلوية. اعتماداً على تذبذبات Ca^{2+} تُحرر أحماضاً أمينة استثارية مثل الكلوماتات من قبل الخلايا النجمية وتعدل النشاط المشبكي. قد نجمع المعلومات المستقبلية في شبكة دبق نجمية عن طريق إرسال إشارة Ca^{2+} ضمن شبكة الدبق النجمية المقرونة كهربائياً.*



الاتصال خلية عصبية - خلية نجمية

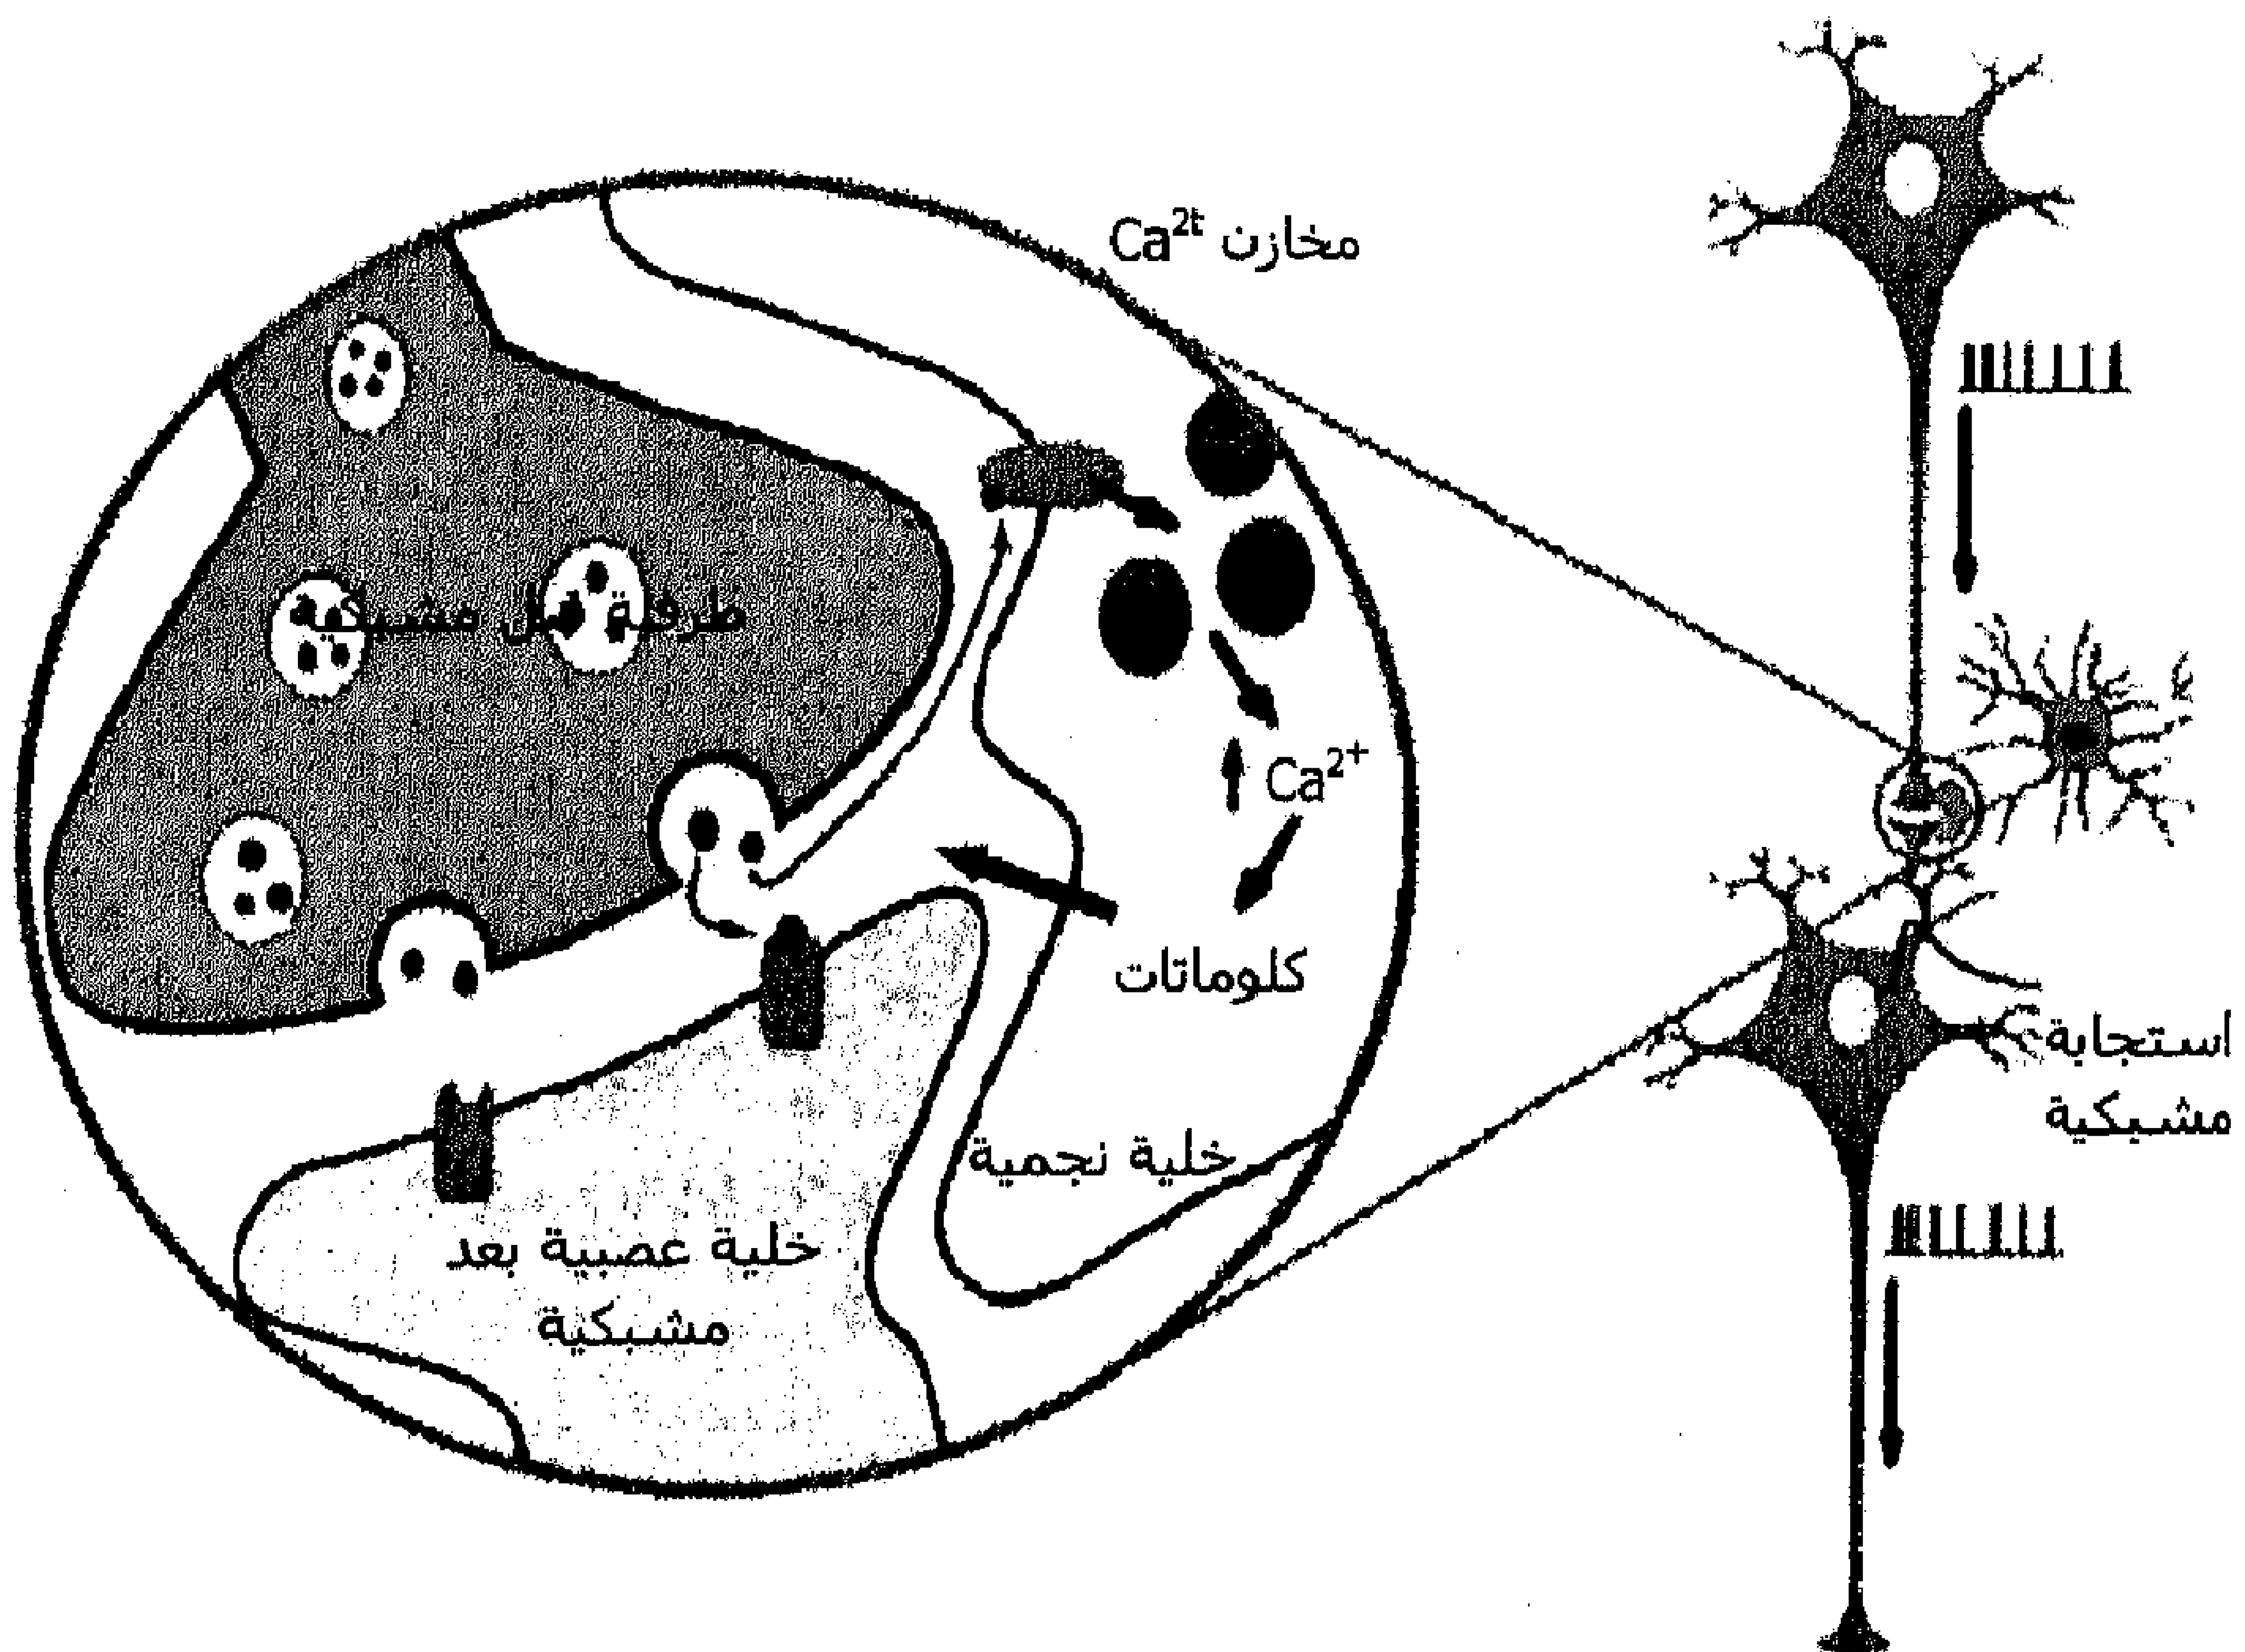
كان يُعتقد كلاسيكياً بأن خلايا الدبق هي خلايا غير قابلة للإثارة، لأنها على عكس الخلايا العصبية لا تُظهر إثارة كهربائية. مع ذلك، تمتلك خلايا الدبق شكلاً من الإثارة الخلوية المعتمدة على تغيرات تركيز Ca^{2+} الخلوي (للمراجعة انظر Volterra et al., 2002). في الواقع منذ أكثر من عقد بقليل أظهرت دراستان رائدتان منفذتان على خلايا الثقافات، بأن تحفيز خلية نجمية إما ميكانيكياً أو بكلوماتات ناقل عصبوني يسبب ارتفاع Ca^{2+} للخلية النجمية، وقد ينتشر بعد ذلك بشكل غير متناقض إلى الخلايا النجمية المجاورة على شكل موجة من Ca^{2+} المرتفع، التي يمكن أن تمتد إلى عدة مئات من الميكرومترات (Cornell-Bell et at., 1990، Newman & Zahs, 1997، Charles, Merrill, Dirksen & Sandreson, 1991، Innocenti, Parpura, & Haydon, 2000). بالتالي، يمكن أن تعمل تغيرات Ca^{2+} تلك كإشارة خلوية، يمكن أن تنتشر بين الخلايا النجمية بسرعة منخفضة نسبياً (Schipke et at,. 2002) مشكلةً نوعاً جديداً من الاتصال الخلوي بعيد المدى والبطيء في الجهاز العصبي. بالإضافة لذلك، عرضت الدراسات المنفذة في شرائح الدماغ، بأن الخلايا النجمية في مناطق مختلفة من الدماغ تظهر ارتفاعات Ca^{2+} وتذبذبات تحدث تلقائياً (Aguado, Espinosa-Parrilla, Carmona, & Soriano, 2002، Netl, Oloff, & McCarthy, 2002، Parri, Gould, & Crunelli, 2001). لقد ظهر أن عدداً كبيراً من المواد النشيطة العصبية – بما في

ذلك النواقل العصبونية – ترفع تركيز Ca^{2+} داخل الخلية في الخلايا النجمية (الشكل 5) (Verkhratsky, Orkand, & Kettenmann, 1998 ،Porter & McMarthy, 1997) في الواقع، فإن التطبيقات الخارجية للكلوماتات (Porter & McMarthy, 1996)، و5-hydroxytryptamine (5-HT)، ولـ norepinephrine (Muydermann et at. 1998) و histamin (Shelton, & McMarthy, 2000)، (Hagborg, Blomstrand, Nisson, Tamir, & Hansson, 1998)، و(Shelton, & McMarthy, 2000)، و acetylchoLine (Sharma & Vijagakaghavan, 2001)، Araque, Martin, Perea, Arellano, & Buno, 2002) و acetylcholine ولـ ATP (Guthrie et at., 1999)، والحامض غاما الأميني الزبدي (GABA) (Kang, Jiang, Goldman, & Nedergaard 1998) يمكن أن تزيد مستويات Ca^{2+} الداخلية لخلايا الدبق من خلال تنشيط المستقبلات المرسلة بسرعة من قبل الخلايا النجمية. بالانسجام مع هذه النتائج، تم الشرح عملياً بأن تحرير النواقل العصبونية من قبل الطرفيات الشبكية، يمكن أن يرفع Ca^{2+} للخلية النجمية (Araque et at., 2002، Bezzi et at. 1998، Dani et at. 1992، Kang et at., 1998، Kulik, Haentzsch, Luckermann, Reichelt, & Ballanyi, 1999، Nett et at. 2002، Parri et at., 2001، Pasti et at., 1997، Porter, & McCarthy, 1996) وبالتالي، فإن الإثارية الخلوية للخلية النجمية – أي مستويات Ca^{2+} للخلية النجمية – هي سيطرة النشاط المشبكي. علاوة على ذلك، فلقد عرضت النتائج الأخيرة المكتسبة في منطقة الحُصَيْن hippocampus للجرذان – وهي منطقة دماغية يعتقد بأنها مشتركة في عمليات التعلّم والذاكرة – أن إشارة Ca^{2+} للخلية النجمية لا تعكس ببساطة النشاط المشبكي، وإنما تظهر الخلايا النجمية خصائص تكاملية من أجل معالجة المعلومات المشبكية (Perea & Araque, 2005). في الواقع، لقد بيّنا بأن الخلايا النجمية تميز بين نشاط طرفيات مشبكية مختلفة تابعة لممرات (مسالك) محوارية مختلفة، وأنه يمكن أن تكون إشارة Ca^{+2} لخلية نجمية مُثارة مشبكياً مُعدلة بشكلٍ ثنائي الاتجاه بواسطة تآثر مدخلات مشبكية مختلفة بكونها منشطة أو مضغوطة (مخفضة) اعتماداً على النشاط المشبكي.

كما عرضنا أن هذا التعديل (التنظيم) يتحكم بالتوسع الخلوي لإشارة Ca^{2+}، وأن هذا ناتج عن وجود خصائص داخلية خلوية في الخلايا النجمية. تشير هذه النتائج مجتمعةً إلى أن الخلايا النجمية موهوبة بمواصفات حسابية خلوية تكامل المعلومات المشبكية (Perea, & Araque, 2005). وبالتالي، فبالإضافة إلى الخلية العصبية يمكن اعتبار الخلايا النجمية كعناصر خلوية مشتركة في معالجة المعلومات بالنظام العصبي. قد تُركب وتطلق خلايا الدبق عدداً كبيراً من المواد النشيطة العصبية مثل الكلوماتات أو D-Servine، أو TNF-a أو ATP (Araque, Parpura, Sanzqiri, & Haydon, 1998a، Araque, Sanzgiri, Parpura & Haydon, 1998b، Araque, Li, Doyle, & Haydon, 2000، Araque & Perea, 2005، Arcuino et at., 2002، Beatlie et at. 2002, Coco et at. 2003

Haydon & Araque, 2002، Newman, 2003a, Wolosker, Blackshaw, & Snyder, 1999، Zhang et at., 2003) عندما تُحرر هذه النواقل – المسماة بالنواقل الدبقية gliotranomitlers من قبل الخلايا الدبقية (Bezzi & Votlerra, 2001) – يمكن أن تُستخدم كإشارات خلوية بينية من الخلايا الدبقية، يمكن أن ترسل الإشارة عكسياً إلى الخلايا العصبية منظمة الإثارية العصبونية، وتحرير النواقل العصبية من الطرفيات قبل المشبكية (الشكل 5) (للمراجعة انظر Newman, 2003b، Auld & Robitaille, 2003، Araque & Perea, 2004).

الشكل (5) *الرسم التخطيطي الذي يوضح المفهوم الجديد للفسيولوجية المشبكية - مشبك ثلاثي - حيث تلعب الخلايا النجمية دوراً فعالاً بتبادل المعلومات مع العناصر المشبكية. زوج من الخلايا العصبية مع اتصال قبل وبعد مشبكي مبينة. بالإضافة إلى خلية نجمية قريبة جداً من المشبك.أثناء النشاط المشبكي تثير النواقل العصبونية المحررة من الطرفيات قبل المشبكية كمونات قبل مشبكية. تصل النواقل العصبونية أخيراً إلى غشاء الخلية النجمية منشطةً المستقبلات التي تزيد مستويات* Ca^{2+} *للخلية النجمية من خلال تحرير* Ca^{2+} *من المخازن الداخلية. قد تثير* Ca^{2+} *المرتفعة للخلية النجمية تحرير مواد نشيطة عصبية مثل كلوماتات الناقل الكيميائي التي يمكن أن تعدل النقل المشبكي.*



في الواقع، عرضنا بأنه يتم في خلايا الحُصيّن المثقفة تحرير كمية من النواقل المشبكية عندما يخفض بشكل عابر كمون فعل واصل إلى الطرفيات المشبكية بالتحفيز الذي أثار ارتفاعات Ca^{2+} في الخلايا النجمية. بالإضافة إلى ذلك، سببت ارتفاعات Ca^{2+} للخلية النجمية زيادة عابرة في تردد

التيارات بعد المشبكية الصغيرة (أي الأحداث الوَحْدية الناجمة عن تحرير تلقائي لناقل من طرفيات قبل مشبكية والذي لا يعتمد على توليد كمونات الفعل).

تسوى هذه الظواهر التعديلية للنقل المشبكي بالحمض الأميني كلوماتات الذي حُرر من خلال عمليات معتمدة على Ca^{2+} من الخلايا النجمية، التي نشطت إما مستقبلات كلوماتات أيضية التعادل قبل مشبكية، أو مستقبلات – تَمْداوية NMDA receptor على الترتيب (Araque et at., 1988a, 1998b). بشكل مثير للانتباه، فإن هذا التعديل المسوى بكلوماتات محرضة من قبل خلية نجمية للإرسال المشبكي، قد وجد في كلا المشابك المولدة للكلوماتات الاستثارية والمشابك المولدة لـــ GABA التثبيطية. على الرغم من أن هذا التعديل الواسع العام لكلا نوعي المشابك، يحتمل أن يكون بشكل محدد مُسيطر عليه في الدماغ، يُقترح أن أنواع مختلفة من المشابك قد تكون تحت سيطرة الخلايا النجمية. كما أظهر أيضاً أن أنواع الحمض الأميني الكلوماتات المحررة من الخلايا النجمية تعدل الإرسال المشبكي في إعدادات وتحضيرات أكثر سلامةً. في شبكية العين، فهو يعد النشاط المُثار بالضوء للخلايا العقدية (Newman & Zahs, 1998)، وفي الحُصيّن، ينشط النقل التثبيطي (Kang et at; 1998; Liu, Xu, Arcuino, Kang, & Nedergaard, 2004)، ويزيد احتمال النقل المشبكي الاستثاري التلقائي (Fiacco, & McCarthy, 2004).

بالإضافة إلى الكلوماتات، يمكن أن تُحرر الخلايا الدبقية أيضاً أحماضاً أمينية أخرى (مثل الأسبارتيت aspartate، والتايرين taurine)، وهمضيدات عصبونية (ببتدات عصبونية) neuropeptides، وستيرويدات (مركبات شبيهة بالكولسترول) Steroids، وايكومانويدات ecicosanoids، وعوامل نمو (للمراجعة انظر Bezzi & Voltana, 2001). على الرغم من أن معظم النواقل الدبقية قد تؤثر على الإرسال المشبكي، فإن الحقيقة قد تم عرضها فقط في بضعة حالات. إلى جانب الكلوماتات، من المحتمل أن تكون D-Serine وATP هي الأمثلة المدروسة الأفضل للنواقل الدبقية التي يمكن أن تعدل الإرسال المشبكي (على سبيل المثال: Boehning & Snyder, 2003، Koizumi, Fujishita, Tsuda, Shigemoto-Mogami, & Inoue, 2003، Miller, 2004، Zhang et at., 2003) لقد عرضت عدة دراسات بأن الخلايا النجمية يمكنها أيضاً أن تعدل الإثارية العصبونية. باستخدام ثقافات خلايا الحُصيّن للجرذان، تم إظهار بأن ارتفاعات مستويات Ca^{2+} الخلوية لخلية نجمية تؤدي إلى تحرير الكلوماتات المعتمد على Ca^{2+}، والذي أثار تيارات داخلة بطيئة معتمدة على الكلوماتات (SIC) في الخلايا العصبية المجاورة بتنشيط مستقبلات الكلوماتات أيونية التعادل (Araque et at., 1998q, 1998b, 2000). هذا التحفيز المباشر للعصبونات بعد المشبكية بتحرير كلوماتات من خلايا نجمية يمكن أن يُرصد فإزالات

استقطاب غشائية عصبونية، قد تسبب قدح تفريغات كمونات الفعل (Araque et at., 1998a، Hassinger et at., 1995). كما تم عرض SIC المُسوّاة بكلوماتات محرضة من قبل خلية نجمية في خلايا عصبية في شرائح المُهاد الحادة (Parri et at., 2001) وشرائح الحُصَيْن (Fellin et at.; 2004، Angulo, kozlov, Charpak, & Adinat, 2004، Perea & Araque, 2004). يمكن أن تحدث SICs العصبونية بشكل متزامن في خلايا عصبية متعددة، يُقترح بأنها قد تزامن النشاط العصبوني (Angulo et at., 2004, Fellin et at., 2004). علاوة على ذلك، يمكن أن ترسل الخلايا النجمية المنشطة بمشبك معين المعلومات إلى خلايا عصبية ومشابك مجاورة، لأنه يمكن لخلية نجمية واحدة أن تتصل بخلايا عصبية متعددة، وأن تؤثر في النهاية على حوالي 140.000 مشبك (Ventura & Harris, 1999) (الشكل 6). بالإضافة إلى ذلك، يمكن أن يعمل إرسال الإشارة الخلوية البينية بين خلايا نجمية عبر أمواج Ca^{2+} كآلية نقل معلومات أبطأ وبعيدة المدى في الجهاز العصبي المركزي، ممثلاً مسلكاً أو ممر معلومات موازٍ بديل للاتصالات المعتمدة على كمون الفعل السريع.

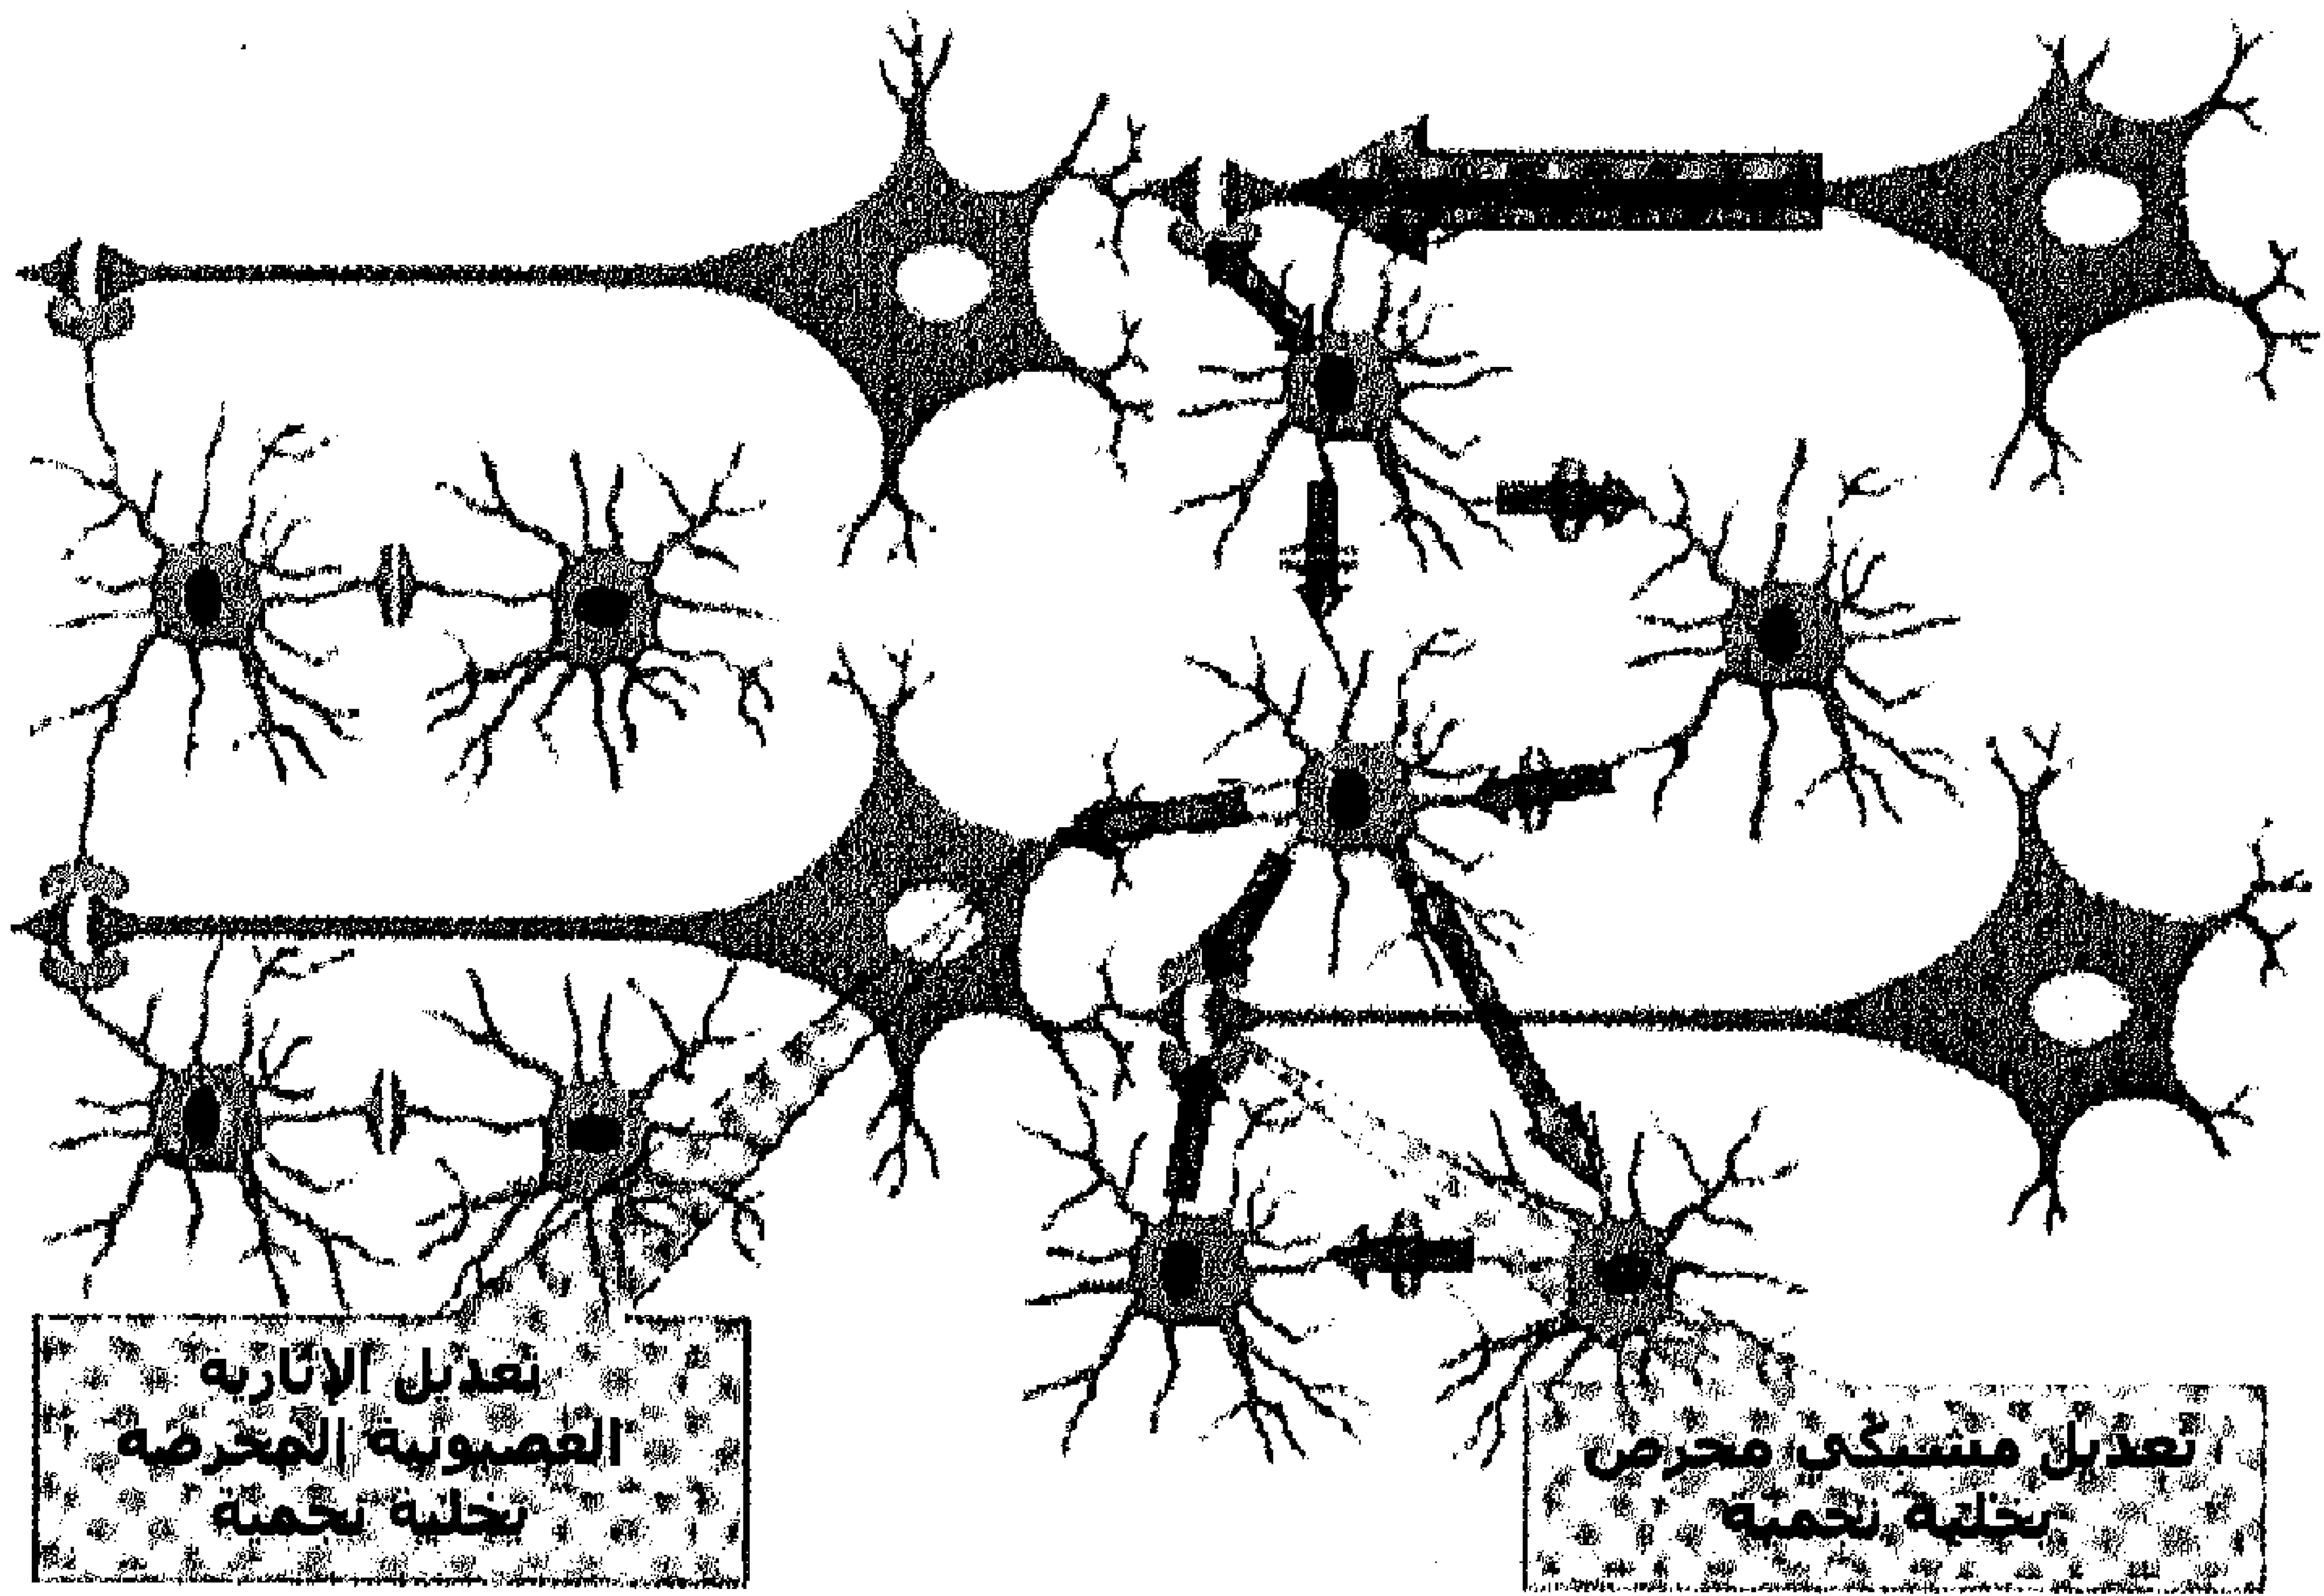
في الخلاصة، تظهر الخلايا النجمية كلا شكلي الإثارية المعتمدة على تغيرات تركيز Ca^{2+} الخلوية. ولديها شكلٌ من الاتصالات الخلوية البينية المعتمد على أمواج Ca^{2+} الخلوية. تُقدح الإثارية الخلوية للخلية النجمية وتُنظم بواسطة النشاط المشبكي. وتُحرر الخلايا النجمية بدورها نواقل دبقية تعدل النشاط الكهربائي العصبوني للنقل المشبكي. وكنتيجة لعرض وشرح هذه الأشكال الجديدة لإرسال الإشارة الخلوية بين الخلايا النجمية والخلايا العصبية، فإن ذلك يدعم وجود ممرات معلوماتية معقدة وجديدة في CNS المعتمدة على وجود اتصالات ثنائية الاتجاه بين الخلايا النجمية والخلايا العصبية، والتي يكون لها تأثيرات ذات صلة على الآليات الخلوية المسؤولة عن معالجة المعلومات في CNS.

الاتجاهات المستقبلية

تمتلك النمذجة العصبونية الحيوية هدفاً يتجلى في تطوير نماذج الشبكات العصبونية الصنعية. في هذا السياق، تصبح معرفة الخصائص الخلوية الدقيقة للجهاز العصبي ضرورية وأساسية. أُنتجت في العقود القليلة الماضية كمية كبيرة من المعرفة حول وظيفة الجهاز العصبي المتعلقة في الغالب بوظيفة الخلايا العصبية. لقد تم حديثاً إظهار الأهمية المحتملة لخلايا الدبق النجمية في الشبكات العصبونية الحيوية. برز أحد أكثر المجالات المتكررة والمثيرة في علم الأعصاب بعد إثبات وجود اتصالات خلوية للخلية النجمية، التي قد تمثل نظام اتصال عصبوني خارجي، ومن المحتمل مع

إمكانية معالجة للمعلومات. علاوة على ذلك، يضيف وجود الاتصال المتبادل بين الخلايا النجمية والخلايا العصبية تعقيداً آخر لممرات الاتصال في الجهاز العصبي.

الشكل (6) *الرسم التخطيطي الذي يوضح مفهوم شبكة الدبق العصبونية. تستجيب الخلايا النجمية إلى النشاط المشبكي بارتفاعات Ca^{2+} الخلوية، بمعنى أن الخلايا العصبية تتصل بالخلايا النجمية. يمكن أن تنتشر هذه الارتفاعات في Ca^{2+} إلى خلايا نجمية أخرى مشكلةً موجة من Ca^{2+} المرتفع، التي يمكن أن تنتشر ببطء إلى مسافات كبيرة نسبياً. وهكذا، فإن الخلايا النجمية توصل بينهم. أخيراً، قد تحرر الخلايا النجمية مواد نشيطة عصبية مثل الكلوماتات أو ATP التي يمكن أن تعدل الإثارية العصبونية والنقل المشبكي. وهكذا، يمكن أن ترسل الخلايا النجمية الإشارة عكسياً إلى خلايا عصبية. تمثل هذه الحلقة من تبادل المعلومات بين الخلايا النجمية والخلايا العصبية شكلاً جديداً من الاتصال الخلوي في CNS.*



وبالتالي، فقد تحّسن التطويرات المستقبلية المتعلقة بالشبكات العصبونية الصنعية (عن طريق تضمين الاحتمالية بتزويد شبكة دبق صنعية) النظام التنظيمي المتوازي بشكل ممتاز. وبالتالي، يجب الأخذ بالاعتبار ثلاثة مكونات مختلفة للجهاز العصبي ككل: شبكة الخلايا النجمية، وشبكة الخلايا العصبية، وأخيراً شبكة الدبق العصبوني المعتمدة على الاتصالات المتبادلة بين الشبكتين السابقتين. تعتمد هذه الشبكات على المستويات التنظيمية المختلفة والمتعاقبة في الدماغ من المستويات الجزيئية إلى الخلوية وعلى ما فوق الخلوية.

على الرغم من أن تقدماً كبيراً قد حدث في السنوات القليلة الماضية في فهمنا للعمليات الجزيئية الخلوية الأساسية في الاتصالات بين الخلايا العصبية والنجمية، فإنه يوجد الكثير من الأسئلة حول الأدوار الوظيفية المعينة بالإضافة إلى الآليات التي قد تشارك بها خلايا الدبق في معالجة المعلومات في CNS. فعلى سبيل المثال، أُثبت جيداً في المستوى المشبكي بأن الخلايا النجمية تستجيب إلى إشارة ناقل عصبوني من خلية عصبية قريبة، وأنه بإمكانها إرسال الإشارة عكسياً إلى خلايا عصبية عبر تحرير نواقل دبقية. مع ذلك، فإنه ما زال مجهولاً وبشكل كبير كيفية ترميز الإشارات القادمة إما الخلية النجمية أو من الطرفية قبل المشبكية أو من كليهما في الطرفية بعد المشبكية، وتحوّلها إلى نشاط خلوي ونشاط شبكة.

إن السلوكيات المعقدة للحيوانات – متضمنةً ما يسمى بالوظائف الأعلى للجهاز العصبي – تبدو معتمدة على الخصائص البارزة التي تستند إلى التعقيد الديناميكي والتفاعلات بين المستويات المختلفة لتنظيم الدماغ. نتيجةً للتعقيد الوظيفي والبنيوي العالي للأجهزة العصبية، فيبدو من المستحيل في أغلب الحالات حتى الوصول إلى تقليد البنية الهندسية وديناميكا الدماغ في شبكة عصبونية صنعية. وبالتالي، فإن هندسة النظام الصنعي المكافئ للجهاز العصبوني الحيوي يمكن أن يعتبر مهمة مستحيلة حالياً. مع أنه، قد يكون من الممكن إنشاء شبكة عصبونية صنعية في المستقبل تدمج خلايا عصبية متصلة مشبكياً في خلفية أو شبكة متوازية لخلايا نجمية، ما قد يؤدي إلى تحسينات في إمكانية الشبكات الصنعية للتصرف، وتنفيذ مهمات مختلفة تفوق قدرة الشبكات العصبونية الصنعية الحالية.

الاستنتاجات

خلال السنوات القليلة الماضية زاد البحث في فسيولوجية الدبق بشكل مميز من معرفتنا الحالية للآليات الخلوية الواقعة تحت سمات متعلقة بفسيولوجية الجهاز العصبي. ومن المعروف جيداً الآن، أن هذه الخلايا تمتلك خصائص كان من المعتقد سابقاً بأنها خاصة بالخلايا العصبية، كالقنوات الأيونية والمستقبلات الغشائية لمعظم النواقل الدبقية والنواقل العصبونية، وأنظمة نقل طاقة الإشارة الوظيفية بالاستجابة إلى إشارات الجزيئات ونواقل المرسلات العصبونية الحامضية الأمينية، والآلية الجزيئية والخلوية لتحرير مواد نشيطة عصبية. وبالتالي، تمتلك الخلايا النجمية الشروط الجزيئية والخلوية التي تُمكنها من مراقبة النشاط المشبكي والإحساس بتركيب البيئة خارج الخلية لمصل الدم. تشكل هذه الخلايا مدمجاً خلوياً مربوطاً بموصلات فجوية، وتعرض نظام إرسال إشارة Ca^{2+} جديد من خلية إلى خلية ضمن شبكات الدبق النجمية. علاوة على ذلك، تتصل الخلايا النجمية والخلايا العصبية بشكل متبادل بين بعضها البعض بتبادل المعلومات عبر تحرير نواقل دبقية ونواقل عصبونية تعدل نشاطها الخلوي ونشاط الشبكة.

لقد تغيرت نظرتنا لفسيولوجية CNS بشكل مثير بعد إثبات وجود ممرات معلوماتية معقدة وجديدة في CNS، التي تعتمد على وجود اتصالات ثنائية الاتجاه بين الخلايا النجمية والخلايا العصبية، التي تمتلك تأثيرات ذات صلة على الآليات الخلوية المسؤولة عن معالجة المعلومات في CNS. وكنتيجة لتلك النتائج، برزت رؤية جديدة لفسيولوجية CNS حيث لم يعد بالإمكان اعتبار CNS بأنه أداء وظيفي بسيط كشبكة خلوية لخلايا عصبية. بالأحرى، يشمل CNS مجموعة معقدة من الشبكات الخلوية التي تضم خلايا عصبية وخلايا دبق. وهكذا، يجب أن تُعتبر CNS كشبكة دبق عصبونية ذات بنية هندسية فائقة.

المراجع

Aguado, F., Espinosa-Parrilla, J.F., Carmona, M.A., & Soriano, E. (2002). Neuronal activity regulates correlated network properties of spontaneous calcium transients in astrocytes in situ. Journal of Neuroscience, 22, 9430-9444.

Angulo, M.C., Kozlov, A.S., Charpak, S., & Audinat, E. (2004). Glutamate released from glial cells synchronizes neuronal activity in the hippocampus. Journal of Neuroscience 24,6920-6927.

Araque, A., Carmignoto, G., & Haydon, P.G. (2001). Dynamic signaling between astrocytes and neurons. Annual Review of Physiology, 63, 795-813.

Araque, A., Li, N., Doyle, R.T., & Haydon, P.G. (2000). SNARE protein-dependent glutamate release from astrocytes. Journal of Neuroscience, 20, 666-673.

Araque, A., Martin, E.D., Perea, G., Arellano, J.I., & Buno, W. (2002). Synaptically eleased acetylcholine evokes Ca^{2+}elevations in astrocytes in hippocampal slices. Journal o fNeuroscience, 22,2443-2450.

Araque, A., Parpura, V., Sanzgiri, R.P., & Haydon, P.G. (998a). Glutamate-dependent astrocyte modulation of synaptic transmission between cultured hippocampal neurons. European Journal of Neuroscience, 10, 2129-2142.

Araque, A., & Perea, G. (2004). Glial modulation of synaptic transmission in culture. Glia, 47,241-248.

Araque, A., Sanzgiri, R.P., Parpura, V., & Haydon, P.G. (1998b). Calcium elevation in astrocytes causes an NMDA receptor-dependent increase in the frequency of miniature synaptic currents in cultured hippocampal neurons. Journal of Neuroscience, 18,822 6829.

Arcuino, G., Lin, J.H., Takano, T., Liu, C., Jiang, L., Gao, Q., Kang, J., & Nedergaard, M. (2002). Intercellular calcium signaling mediated by point-source burst release of ATP. Proceedings of the National Academy of Sciences of the USA, 99 (pp. 9840-845).

Auld, D.S., & Robitaille R. (2003). Glial cells and neurotransmission: An inclusive view of synaptic function. Neuron, 40, 389-400.

Banker, G.A. (1980). Trophic interactions between astroglial cells and hippocampal neurons in culture. Science, 209, 809-810.

Barres, B.A., Chun, LL.Y., & Corey,D.P. (1990). Ion channels in vertebrate glia. Annual Review of Neuroscience, 13,441-474.

Bastiani, M.J., & Goodman C.S. (1986). Guidance of neuronal growth cones in the grasshopper embryo. III. Recognition of specific glial pathways. Journal of Neuroscience, 6,3542-3551.

Beattie, E.C., Stellwagen, D., Morishita, W., Bresnahan, J.C., Ha, B.K., Von Zastrow, M., Beattie, M.S., & Malenka, R.C. (2002). Control of synaptic strength by glial TNFalpha. Science, 295,2282-2285.

Bennett,M.V., Barrio, L.C., Bargiello,T.A., Spray, D.C., Hertzberg,E.,& Saez, J.C. (1991). Gap junctions: New tools, new answers, new questions. Neuron, 6, 305-320.

Bergles, D.E., Diamond, J.S., & Jahr, C.E. (1999). Clearance of glutamate inside the synapse and beyond. Current Opinion in Neurobiology, 9, 293-298.

Bernardinelli, Y., Magistretti, P.J., & Chatton, J.Y. (2004). Astrocytes generate Na+-mediated metabolic waves. Proceedings of the National Academy of Sciences of the USA. 101(pp.14937-14942).

Bezzi, P., Carmignoto, G., Pasti, L., Vesce, S., Rossi, D., Lodi Rizzini, B., Pozzan, T., & Volterra, A. (1998). Prostaglandins stimulate calciumdependent glutamate release in astrocytes. Nature, 391, 281-285.

Bezzi P., & Volterra A. (2001). A neuron-glia signalling network in the active brain. Current Opinion in Neurobiology, 11, 387-394.

Boehning D., & Snyder S.H. (2003). Novel neural modulators. Annual Review of Neuroscience, 26, 105-131.

Charles, A.C., Merrill, J.E., Dirksen, E.R., & Sanderson, M.J. (1991). Intracellular signaling in glial cells: Calcium waves and oscillations in response to mechanical stimulation and glutamate. Neuron, 6, 983-992.

Charles, A.C., & Giaume, C. (2002). Intercellular calcium waves in astrocytes: Underlying mechanisms and functional significance. In A. Volterra, P.J. Magistretti., & P.G. Haydon (Eds.), The tripartite synapse: Glia in synaptic transmission (pp. 110-126). New York: Oxford University Press.

Choi, D.W., & Rothman, S.M. (1990). The role of glutamate neurotoxicity in hypoxic-ischemic neuronal death. Annual Review of Neuroscience, 13, 171-182.

Coco, S., Calegari, P., Pravettoni, E., Pozzi, D., Taverna, E., Rosa, P., Matteoli, M., & Verderio, C. (2003). Storage and release of ATP from astrocytes in culture. Journal of Biological Chemistry, 278, 1354-1362.

Cornell-Bell, A.H., Finkbeiner, S.M., Cooper, M.S., & Smith, S.J. (1990). Glutamate induces calcium waves in cultured astrocytes: Long-range glial signaling. Science, 247,470-473.

Cotrina, M.L., Lin, J.H., Alves-Rodrigues, A., Liu, S., Li, J., Azmi-Ghadimi, H., Kang, J., Naus, C.C., & Nedergaard, M. (1998). Connexins regulate calcium signaling by ontrolling ATP release. Proceedings of the National Academy of Sciences of the USA, 95(pp.15735-15740).

Dani, J.W., Chernjavsky, A., & Smith, S.J. (1992). Neuronal activity triggers calcium waves in hippocampal astrocyte networks. Neuron, 8,429-440.

Fellin, T., Pascual, O., Gobbo, S., Pozzan, T., Haydon, P.G., & Carmignoto, G. (2004). Neuronal synchrony mediated by astrocytic glutamate through activation of extrasynaptic NMDA receptors. Neuron, 43, 729-743.

Fiacco, T.A., & McCarthy, K.D. (2004). Intracellular astrocyte calcium waves in situ increase the frequency of spontaneous AMPA receptor currents in CA1 pyramidal neurons. Journal of Neuroscience, 24, 722-732.

Guthrie, P.B., Knappenberger, J., Segal, M., Bennett, M.V.L., Charles, A.C., & Kater, S.B. (1999). ATP released from astrocytes mediates glial calcium waves. Journal of Neuroscience, 19,520-52.

Hagberg, G.B., Blomstrand, P., Nilsson, M., Tamir, H., & Hansson, E. (1998). Stimulation of 5-HT2A receptors on astrocytes in primary culture opens voltage-independent Ca^{2+} channels. Neurochemistry International, 32,153-162.

Hamprecht, B., & Dringen, R. (1995). Energy metabolism. In H. Kettenman & B.R. Ransom (Eds.), Neuroglia (pp. 473-487). New York: Oxford University Press.

Hassinger, T.D., Atkinson, P.B., Strecker, G.J., L.R., Dudek, F.E., Kossel,A.H., & Kater S.B. (1995). Evidence for glutamate-mediated activation of hippocampal neurons by glial calcium waves. Journal of Neurobiology, 28, 159-170.

Hassinger, T.D., Guthrie, P.B., Atkinson, P.B., Bennett, M.V., & Kater, S.B. (1996). An extracellular signaling component in propagation of astrocytic calcium waves. Proceedings of the National Academy of Sciences USA, 93, 13268-13273.

Hatten M.E.,& Mason,C.A. (1990). Mechanisms of glial-guided neuronal migration in vitro and in vivo. Experientia, 46, 907-916.

Haydon, P.G.,& Araque,A. (2002). Astrocytes as modulators of synaptic transmission. In A. Volterra, P.J. Magistrelti., & P.G. Haydon (Eds.), The tripartite synapse: Glia in synaptic transmission (pp. 185-198). New York: Oxford University Press.

Hertz, L., & Peng, L. (1992). Effects of monoamine transmitters on neurons and astrocytes: Correlation between energy metabolism and intracellular messengers. Progress in Brain Research, 94,283-301.

Innocenti, B., Parpura, V., & Haydon, P.G. (2000). Imaging extracellular waves of glutamate during calcium signaling in cultured astrocytes. Journal of Neuroscience, 20,1800-1808.

Johnson, P.W.,Abramow-Newerly,W., Seilheimer, B., Sadoul, R., Tropak, M.B., Arquint, M., Dunn, R.J., Schachner, M., & Roder J.C. (1989). Recombinant myelin-associaled glycoprotein confers neural adhesion and neurite outgrowth function. Neuron, 3, 377-385.

Kandel, E.R., Schwartz, J.H., & Jessell, T.M. (2000). Principles of neural science (4^{th}ed.). New York: McGraw-Hill.

Kang, J., Jiang, L., Goldman, S.A., & Nedergaard, M. (1998). Astrocyte-mediated potentiation of inhibitory synaptic transmission. Nature Neuroscience. 1, 683-692.

Koizumi, S., Fujishita, K., Tsuda, M., Shigemoto-Mogami, Y., & Inoue, K. (2003). Dynamic inhibition ofexcitatory synaptic transmission by astrocyte-derived ATP in hippocampal cultures. Proceedings of the National Academy of Sciences USA, 100 (pp. 11023-11028).

Kulik, A., Haentzsch, A., Luckermann, M., Reichelt, W., & Ballanyi, K. (1999). Neuron-glia signaling via a_1 adrenoceptor-mediated Ca^{2+} release in Bergmann glial cells in situ. Journal of Neuroscience, 19, 8401-8408.

Kuno, M. (1995). The synapse: Function, plasticity, and neurotrophism. New York: Oxford University Press.

Kuwada, J.Y. (1986). Cell recognition by neuronal growth cones in a simple vertebrate embryo. Science, 233,740-746.

Largo, C., Cuevas, P., Somjen, G.G., Martin del Rio, R., & Herreras, O. (1996). The effect of depressing glial function in rat brain in situ on ion homeostasis, synaptic transmission, and neuron survival. Journal of Neuroscience, 16, 1219-1229.

Le Roux, P.D., & Reh, T.A. (1994). Regional differences in glial-derived factors that promote dendritic outgrowth from mouse cortical neurons in vitro. Journal of Neuroscience, 14, 4639-4655.

Liu, Q.S., Xu, Q., Arcuino, G., Kang, J., & Nedergaard, M. (2004). Astrocyte-mediated activation of neuronal kainate receptors. Proceedings of the National Academy of Sciences USA, 101 (pp. 3172-3177).

Magistretti, P.J., Sorg, O., Yu, N., Pellerin, L., de Rham, S., & Martin, J .L. (1994). Regulation of astrocyte energy metabolism by neurotransmitters. Renal Physiological Bio- chemistry, 17, 168-171.

Mennerick, S., & Zorumski, C.F. (1994). Glial contributions to excitatory neurotransmission in cultured hippocampal cells. Nature, 368, 59-62.

Miller, R.F. (2004). D-serine as a glial modulator of nerve cells. Glia, 47,275-288.

Muyderman, H., Nilsson, M., Blomstrand, F., Khatibi, S., Olsson, T., Hansson, E., & Rönnbäck, L. (1998). Modulation of mechanically induced calcium waves in hippocampal astroglial cells. Inhibitory effects of ±1-adrenergic stimulation. Brain Research, 793,127-135.

Nedergaard, M., Ransom, B., & Goldman, S.A. (2003). New roles for astrocytes: Redefining the functional architecture of the brain. Trends in Neurosciences, 26, 523-530.

Nett, W.J., Oloff, S.H., & McCarthy, K.D. (2002). Hippocampal astrocytes in situ exhibit calcium oscillations that occur independent of neuronal activity. Journal of Neurophysiology, 87, 528-537.

Newman, E.A. (2003a). Glial cell inhibition of neurons by release of ATP. Journal of Neuroscience, 23,1659-1666.

Newman, E.A. (2003b). New roles for astrocytes: Regulation of synaptic transmission. Trends Neuroscience, 26,536-542.

Newman, E.A., & Zahs, K.R. (1997). Calcium waves in retinal glial cells. Science, 275,844-847.

Newman, E.A., & Zahs, K.R. (1998). Modulation ofneuronal activity by glial cells in the retina. Journal of Neuroscience 18,4022-4028.

Nicholls,J.G., Martin, A.R.,& Wallace, B.G.(1992). From neuron to brain: A cellular and molecular approach to the function of the nervous system. Sunderland, MA: Sinauer Associates.

Noble, M., Fok-Seang, J., & Cohen, J. (1984). Glia are a unique substrate for the in vitro growth of central nervous system neurons. Journal of Neuroscience, 4, 1892-1903.

Orkand, R.K., Nicholls, J.G., & Kuffler, S.W. (1966). Effect of nerve impulses on the membrane potential of glial cells in the central nervous system of amphibia. Journal of Neurophysiology, 29, 788-806.

Parri, H.R., Gould, T.M., & Crunelli, V. (2001). Spontaneous astrocytic Ca2+ oscillations in situ drive NMDAR-mediated neuronal excitation. Nature Neuroscience, 4, 803-812.

Pasti, L., Volterra, A., Pozzan, T., & Carmignoto, G. (1997). Intracellular calcium oscillations in astrocytes: A highly plastic, bidirectional form of communication between neurons and aslrocytes in situ. Journal of Neuroscience, 17, 7817-7830.

Pellerin, L., & Magistretti, P.J. (2004). Neuroenergetics: Calling upon astrocytes to satisfy hungry neurons. Neuroscientist, 10, 53-62.

Perea, G., & Araque, A. (2005). Properties of synaptically evoked astrocyte calcium signal reveal synaptic information processing by astrocytes. Journal of Neuroscience, 25,2192-2203.

Peters, A.,Palay,S.L.,& Webster, H.F. (1991). The fine structure of the nervous system: Neurons and their supporting cells (3rd ed.). New York: Oxford University Press.

Pfrieger,F.W., & Barres, B.A. (1995). What the fly's glia tell the fly's brain. Cell, 83,671-674.

Porter, J.T., & McCarthy, K.D. (1996). Hippocampal astrocytes in situ respond to glutamate released from synaptic terminals. Journal of Neuroscience, 16, 5073-5081.

Porter, J.T., & McCarthy K.D. (1997). Astrocytic neurotransmitter receptors in situ and in vivo. Progress in Neurobiology, 51,439-455.

Rakic, P. (1990). Principles of neural cell migration. Experientia, 46,882-891.

Schipke, C.G., Boucsein, C., Ohlemeyer, C., Kirchhoff, F., & Kettenmann, H. (2002). Astrocyte Ca2+ waves trigger responses in microglial cells in brain slices. The FASEB Journal, 16,255-257.

Schousboe, A. (1981). Transport and metabolism of glutamate and GABA in neurons and glial cells. International Review in Neurobiology, 22, 1-45.

Sharma, G., & Vijayaraghavan, S. (2001). Nicotinic cholinergic signaling in hippocampal astrocytes involves calcium-induced calcium release from intracellular stores. Proceedings of the National Academy of Sciences USA, 98 (pp. 4148-4153).

Shelton, M.K., & McCarthy, K.D. (2000). Hippocampal astrocytes exhibit Ca^{2+}-elevating muscarinic cholinergic and histaminergic receptors in situ. Journal of Neurochemistry, 74,555-563.

Shepherd, G.M. (1994). Neurobiology. New York: Oxford University Press.

Slezak, M., & Pfrieger, F.W. (2003). New roles for astrocytes: Regulation of CNS synaptogenesis. Trends in Neuroscience, 26, 531-535.

Sneyd, J., Charles, A.C., & Sanderson, M.J. (1994). A model for the propagation of intercellular calcium waves. American Journal of Physiology, 266, C293-C302.

Sontheimer, H. (1994). Voltage-dependent ion channels in glial cells. Glia, 11,156-172.

Sul, J.Y., Orosz, G., Givens, R.S., & Haydon, P.G. (2004). Aslrocytic connectivity in the hippocampus. Neuron Glia Biology, 1, 3-11.

Swanson, R.A., & Choi, D.W. (1993). Glial glycogen stores affect neuronal survival during glucose deprivation in vitro. Journal of Cerebral Blood Flow and Metabolism, 13, 162-169.

Szatkowski, M., Barbour, B., & Attwell, D. (1990). Non-vesicular release of glutamate from glial cells by reversed electrogenic glutamate uptake. Nature, 348,443-446.

Takeshima, T., Shimoda, K., Sauve, Y., & Commissiong, J.W. (1994). Astrocyte-dependent and -independent phases of the development and survival of rat embryonic day 14 mesencephalic, dopaminergic neurons in culture. Neuroscience, 60, 809-823.

Takuma, K., Baba, A., & Matsuda, T. (2004). Astrocyte apoptosis: Implications for neuroprotection. Progress in Neurobiology, 72, 111-27.

Tsacopoulos, M., & Magistretti, P.J. (1996). Metabolic coupling between glia and neurons. Journal of Neuroscience, 16, 877-885.

Ullian, E.M., Christopherson, K.S., & Barres, B.A. (2004). Role for glia in synaptogenesis. Glia,47,209-216.

Ullian, E.M., Sapperstein, S.K., Christopherson, K.S., & Barres, B.A. (2001). Control synapse number by glia. Science, 291, 657-661.

Ventura, R., & Harris, K.M. (1999). Three-dimensional relationships between hippocampal synapses and astrocytes. Journal of Neuroscience, 19, 6897-6906.

Verkhratsky, A., Orkand,R.K.,& Kettenmann,H.(1998). Glial calcium: Homeostasis and signaling function. Physiological Review, 78, 99-141.

Verkhratsky, A., Solovyeva, N., & Toescu, E.C. (2002). Calcium excitability of glial cells. In A. Volterra, P.J. Magistretti., & P.G. Haydon (Eds.), The tripartite synapse: Glia in synaptic transmission (pp. 99-109). New York: Oxford University Press.

Vernadakis, A. (1996). Glia-neuron intercommunications and synaptic plasticity. Progress in Neurobiology, 49, 185-214.

Volterra, A., Magistretti, P.J., & Haydon, P.G. (2002). The tripartite synapse: Glia in synaptic transmission. New York: Oxford University Press.

Walz, W. (1989). Role of glial cells in regulation of the brain ion microenvironment. Progress in Neurobiology, 33, 309-333.

Wolosker, H., Blackshaw, S., & Snyder, S.H. (1999). Serine racemase: A glial enzyme synthesizing D-serine to regulate glutamate-N-methy1-D-aspartate neurotransmission. Proceedings of the National Academy of Sciences USA, 96 (pp. 13409-13414).

Zhang, J.M., Wang, H.K., Ye, C.Q., Ge, W., Chen, Y., Jiang, Z.L., Wu, C.P., Poo, M.M., & Duan, S. (2003). ATP released by astrocytes mediates glutamatergic activity-dependent heterosynaptic suppression. Neuron, 40, 971-982.

القسم 2

تنبؤ السلاسل الزمنية

الفصل الثالث

تنبؤ السلاسل الزمنية بالشبكات العصبونية التطويرية

ملخص

يقدم هذا الفصل توليفة هجينة من شبكة عصبونية وحوسبة تطويرية لتنبؤ سلسلة زمنية. الشبكات العصبونية هي مرشحات متأصلة لمجال التنبؤ بفضل ميزاتها كالتعلم اللاخطي وتحمّل التشويش. مع ذلك، فإن البحث من أجل البنية الهندسية المثالية للشبكة هي مهمة معقدة وعصبية. وفق هذا السياق، فإن حوسبة تطورية مُوجّهة بمعيار بواس المعلوماتي (Bayesian Information Criterion) تشكل طريقة بحث عامة واعدة من أجل اختيار السمات والنموذج. تم استخدام مجموعة من 10 سلاسل زمنية من مجالات مختلفة لتقييم هذه الاستراتيجية ومقارنتها مع اختيار نموذج تنقيحي، وكذلك مع طرق تنبؤ تقليدية (على سبيل المثال منهجية Holt-Winters وBox-Jenkins).

مقدمة

في أيامنا الحالية تعتبر المنافسة الشديدة بين الأفراد والمنظمات علامة المجتمعات الحديثة، حيث يكون كسب الأفضليات الاستراتيجية مفتاحاً للنجاح. تشكل إمكانية التنبؤ بالمستقبل اعتماداً على بيانات سابقة نفوذاً وفعالية هامة، يمكن أن تدفع المنظمات إلى الأمام. إن تنبؤ السلاسل الزمنية، أي التنبؤ بمتغيرات مرتبة زمنياً – هو أداة هامة وفق هذا السيناريو، حيث يكمن الهدف في التنبؤ بسلوك الأنظمة المعقدة فقط بالنظر إلى الأنماط والنماذج الموجودة في بيانات سابقة. في الحقيقة، يتم التركيز بشكل متزايد على هذا المجال. وقد أدت مساهمات من ميادين تنافس بحوث العمليات والإحصاء والعلوم الحاسوبية إلى طرق تنبؤ صلبة استبدلت الحدس، مثل منهجية Holt-Winters (Winters, 1900) ومنهجية Box-Jenkins (1976). على أية حال، تم تطوير هذه النماذج قبل عقود، حيث غلب عليها قيود حسابية أعلى. وعلى الرغم من أن هذه الطرق تعطي توقعات دقيقة على سلاسل زمنية خطية، فإنها تتسم بعائق مع المكونات المشوشة أو اللاخطية (Shoneburg, 1999)، التي تكثر في الواقع الفعلي (على سبيل المثال، البيانات المالية).

تنشأ طريقة بديلة لتنبؤ السلسلة الزمنية من استخدام شبكات عصبونية صنعية - التي هي نماذج ربطية مُلهمة من سلوك الجهاز العصبي المركزي - بكونها نتاج صنعي جذاب لتصميم الأنظمة الذكية في تطبيقات التنقيب عن بيانات data mining والتحكم. بشكل خاص فإن شبكة الـــ Perceptron متعددة الطبقات هي البنية الهندسية العصبونية الأشهر، حيث تُجمع الخلايا العصبونية في طبقات، ويكون هناك وجود للاتصالات الأمامية فقط، التي تزود بمعلّم أساسي قوي مع ميزات مثل التعلّم اللاخطي وعدم التأثر بالتشويش (Haykin, 1999). في الحقيقة، بدأ استخدام شبكات Perceptron متعددة الطبقات لنمذجة السلاسل الزمنية في أواخر الثمانيات، ويتقدم هذا المجال بثبات منذ ذلك الحين (Lapedes & Farber, 1987، Cortez, Racha, Machado, & Neves, 1995، Huang, X u, & ChanHiLton, 2004). وأُثير الاهتمام بشبكات Perceptron متعددة الطبقات بظهور خوارزمية الانتشار الخلفي عام 1986، ومنذ ذلك الحين، تم اقتراح عدة نماذج مختلفة وسريعة من الخوارزميات كخوارزمية RPROP (Riedmiller, 1994). حتى الآن، تقلل إجراءات التدريب هذه تابع الخطأ ليصبح أصغرياً بضبط البارامترات (أو الأوزان) القابلة للتعديل لبنية هندسية ثابتة، يجب أن توضع مسبقاً. علاوة على ذلك، فالأداء العصبوني حساس لهذا الاختيار، إذ تؤدي الشبكة الصغيرة إلى إمكانيات تعلّم محددة، بينما تفرط الشبكة الكبيرة في ملاءمة معطيات التدريب مسببةً خسارة التعميم.

إن تصميم طبولوجية الشبكة العصبونية (أي الاتصالية) مهمة معقدة معنونة عادةً بإجراءات تجريب وخطأ بسيطة (على سبيل المثال، باستكشاف عدد مختلف من العقدة الخفية)، في استراتيجية بحث عمياء تمر فقط عبر مجموعة صغيرة من التشكيلات الممكنة. اُقترحت طرق أكثر تطوراً وتوسعاً مثل خوارزمية التشذيب Pruning Algorithm (Thimm, Fiesler, 1995)، والخوارزمية الإنشائية Constructive algorithm (Kwok, & Yeung, 1999)، التي تطرح مسعى باتجاه تصميم عصبوني آلي. تقدم إجراءات تسلق التل Hill-Climing هذه عائقين رئيسين: فهي تميل للتقوقع ضمن الحدود الدنيا المحلية، ويبحث عبر جزء صغير من البنى الهندسية بدلاً من كامل فضاء البحث.

لقد قُدّم بديل مختلف بالحوسبة التطويرية التي تدل على عائلة من الإجراءات الحسابية المُلهمة من عملية الاختيار الطبيعي. إن الخوارزميات التطويرية هي مرشحات متأصلة من أجل مهام الأمثلة التي تقوم بتنفيذ بحث عام متعدد النقاط (أو الشعاع) وبتحديد سريع لموقع المناطق عالية النوعية حتى عندما يكون فضاء البحث كبيراً جداً ومعقداً (Michalewicz, 1996). إن التوليفة الهجينة من الحوسبة التطويرية والشبكات العصبونية - المسماة غالباً بالشبكات العصبونية التطويرية evolutionary Neural Networks (Yao, 1999) - هي مرشح مناسب لتصميم طبولوجي بفضل خصائص سطح الخطأ، حيث يكون النقل من البنية الهندسية العصبونية إلى أدائها غير مباشر،

والتغيرات منفصلة، كما يمكن أن تؤدي إلى تأثيرات متقطعة، وقد لا تبدي الطبولوجيات المتشابهة نفس الأداء في حين أن البنى الهندسية المختلفة قد تعطي نواتج خرج متشابهة.

إن مجال تنبؤ السلاسل الزمنية هو مجال خصب لاختبار توليفات عصبونية تطويرية، بما أن الأداء العصبوني سيعتمد ليس فقط على الوضعية الداخلية الطبولوجية، وإنما أيضاً على المجموعة الصحيحة لمداخلها (تأخيرات زمنية). وبالتالي، يقدم العمل الحالي آلية تكيّفية ذاتية لتصميم شبكات Perceptron متعددة الطبقات من أجل توقع مجال واسع من السلاسل الزمنية الحقيقية والصنعية، مثل مسافري خطوط الطيران الجوية (Box-B Jenkins, 1976). تحققت الأمثلة التطويرية بخوارزمية وراثية - بكون العملية بالكامل موجهة بمعيار بواسون المعلوماتي- والإحصائيات البسيطة لنظرية المعلومات، بحيث تمنع المبالغة في الإحكام بإضافة جزء تقييدي للنموذج (Schwarz, 1978)، ثم مقارنة عائق هذه الاستراتيجية بطريقة تجريبية لاختبار نموذج الشبكة العصبونية وبطرق التنبؤ التقليدية، وكان منافساً.

سيتم تنظيم الفصل كالتالي: أولاً، سيتم تقديم المفاهيم الأساسية لتحليل السلسلة الزمنية ونماذج التنبؤ العصبونية. ثانياً، تُوصف بيانات السلاسل الزمنية المستخدمة في التجارب. بعد ذلك، تُعرض القضيتان الرئيسيتان للتنبؤ العصبوني، أي تأخيرات الدخل الزمنية واختيار الطبولوجيا. في القسم التالي، تُوصف وتُختبر الطريقة التطويرية للتصميم العصبوني،وتُقارن النتائج بطرق التنبؤ التقليدية. أخيراً، تُناقش اتجاهات مستقبلية وتُستخلص استنتاجات نهائية.

خلفية

تحليل السلاسل الزمنية

أي سلسلة زمنية هي مجموعة من المشاهدات الدورية المرتبة ($X_1, X_2, ..., X_t$) الحاصلة في مجموعة واسعة من المجالات كالزراعة، أو الفيزياء، أو المالية أو الهندسية ... الخ. في الواقع، يجسد تحليل السلاسل الزمنية منطقة هامة من نظام الإحصائيات (Martridakis, Weelwright, & Hyndman, 1998). يفترض نموذج السلسلة الزمنية ($\hat{X}_t$) بأن المشاهدات غير مستقلة - بمعنى - أنها نماذج سابقة ستحدث في المستقبل. الغرض من النموذج التنبؤي هو الاستيلاء على (أي توقع) السلوك لظاهرة معقدة (في طريقة الصندوق الأسود) وليس على علاقات السبب - والتأثير لمكوناتها الرئيسية. وهذا ناجم عن حقيقة أنه توجد أنظمة عديدة من الصعب جداً فهمها. (على مثال، سلوك سوق الأسهم) على الرغم من كونها ملموسة وحقيقية للتنبؤ.

يُشار إلى أي سلسلة بأنها حتمية، إذا كان من الممكن توقعها تماماً بدقة 100%. عملياً، تحتوي أغلبية السلاسل الزمنية على مكون عشوائي يؤدي إلى خطأ تنبؤ. ولهذا، يُقيّم الأداء الكلي لنموذج ما بقياسات دقة، أي بمجموع مربعات الأخطاء Sum of Squared errors (SSE)، وبجذر متوسط مربع الخطأ root mean squared error (RMSE) المعطية بالمعادلات التالية:

$$SSE = \sum_{i=t+l}^{t+L} e_i^L \quad ; \quad RMSE = \sqrt{\frac{SSE}{L}} \quad (1)$$

حيث أن $e_t = x_t - \hat{x}_t$ – ترمز إلى خطأ التنبؤ. و L – هي عدد التنبؤات (أو التوقعات).

الإحصائية العامة لتحليل السلاسل الزمنية هي معامل الارتباط الذاتي (ضمن المجال [-1.0:1.0])، الذي يعطي قياس الارتباط بين سلسلة ما ونفسها متأخراً بـ K دور، والذي يمكن حسابه كالآتي (Box & Jenkins, 1976):

$$r_K = \frac{\sum_{t=1}^{s-k}(x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^{s}(x_t - \bar{x})} \quad (2)$$

حيث s، $\bar{x}$ – هما حجم السلسلة والمعدل. قد تكون الارتباطات الذاتية مفيدة لتفكيك السمات الرئيسية للسلسلة الزمنية كالمنحني أو الاتجاه والتأثيرات الموسمية (الشكل 1). يمثل الاتجاه نمواً ثابتاً (أو هبوطاً) في البيانات التي تكون ناتجة عن عوامل مثل التضخم أو التحسينات التقنية. يُوجد العامل الموسمي في سلسلة ذات سلوك دوري، وهو شائع جداً في السلاسل الشهرية (على سبيل المثال، مبيعات المثلجات).

إن تقنية Holt-Winters هي تقنية تنبؤ هامة من عائلة طرق التسوية الأسية. يعتمد النموذج ألتنقيبي على بعض الأنماط الباطنية (مثل الاتجاهية والموسمية)، التي تُميّز وتفرق عن ضجيج عشوائي بأخذ معدل القيم التاريخية (Winters, 1960). انتشار هذه التقنية ناجم عن ميزات مثل البساطة في الاستخدام، والتطلب الحسابي المُنخفض، ودقة توقعات المدد القصيرة، وبخاصة مع السلاسل الموسمية. يمكن أن يُعرّف النموذج العام بأربع معادلات (Hanke & Reitsch, 1989):

$$F_t = \alpha \frac{x_t}{S_{t-k}} + (1-\alpha)(F_{t-1} + T_{t-1})$$

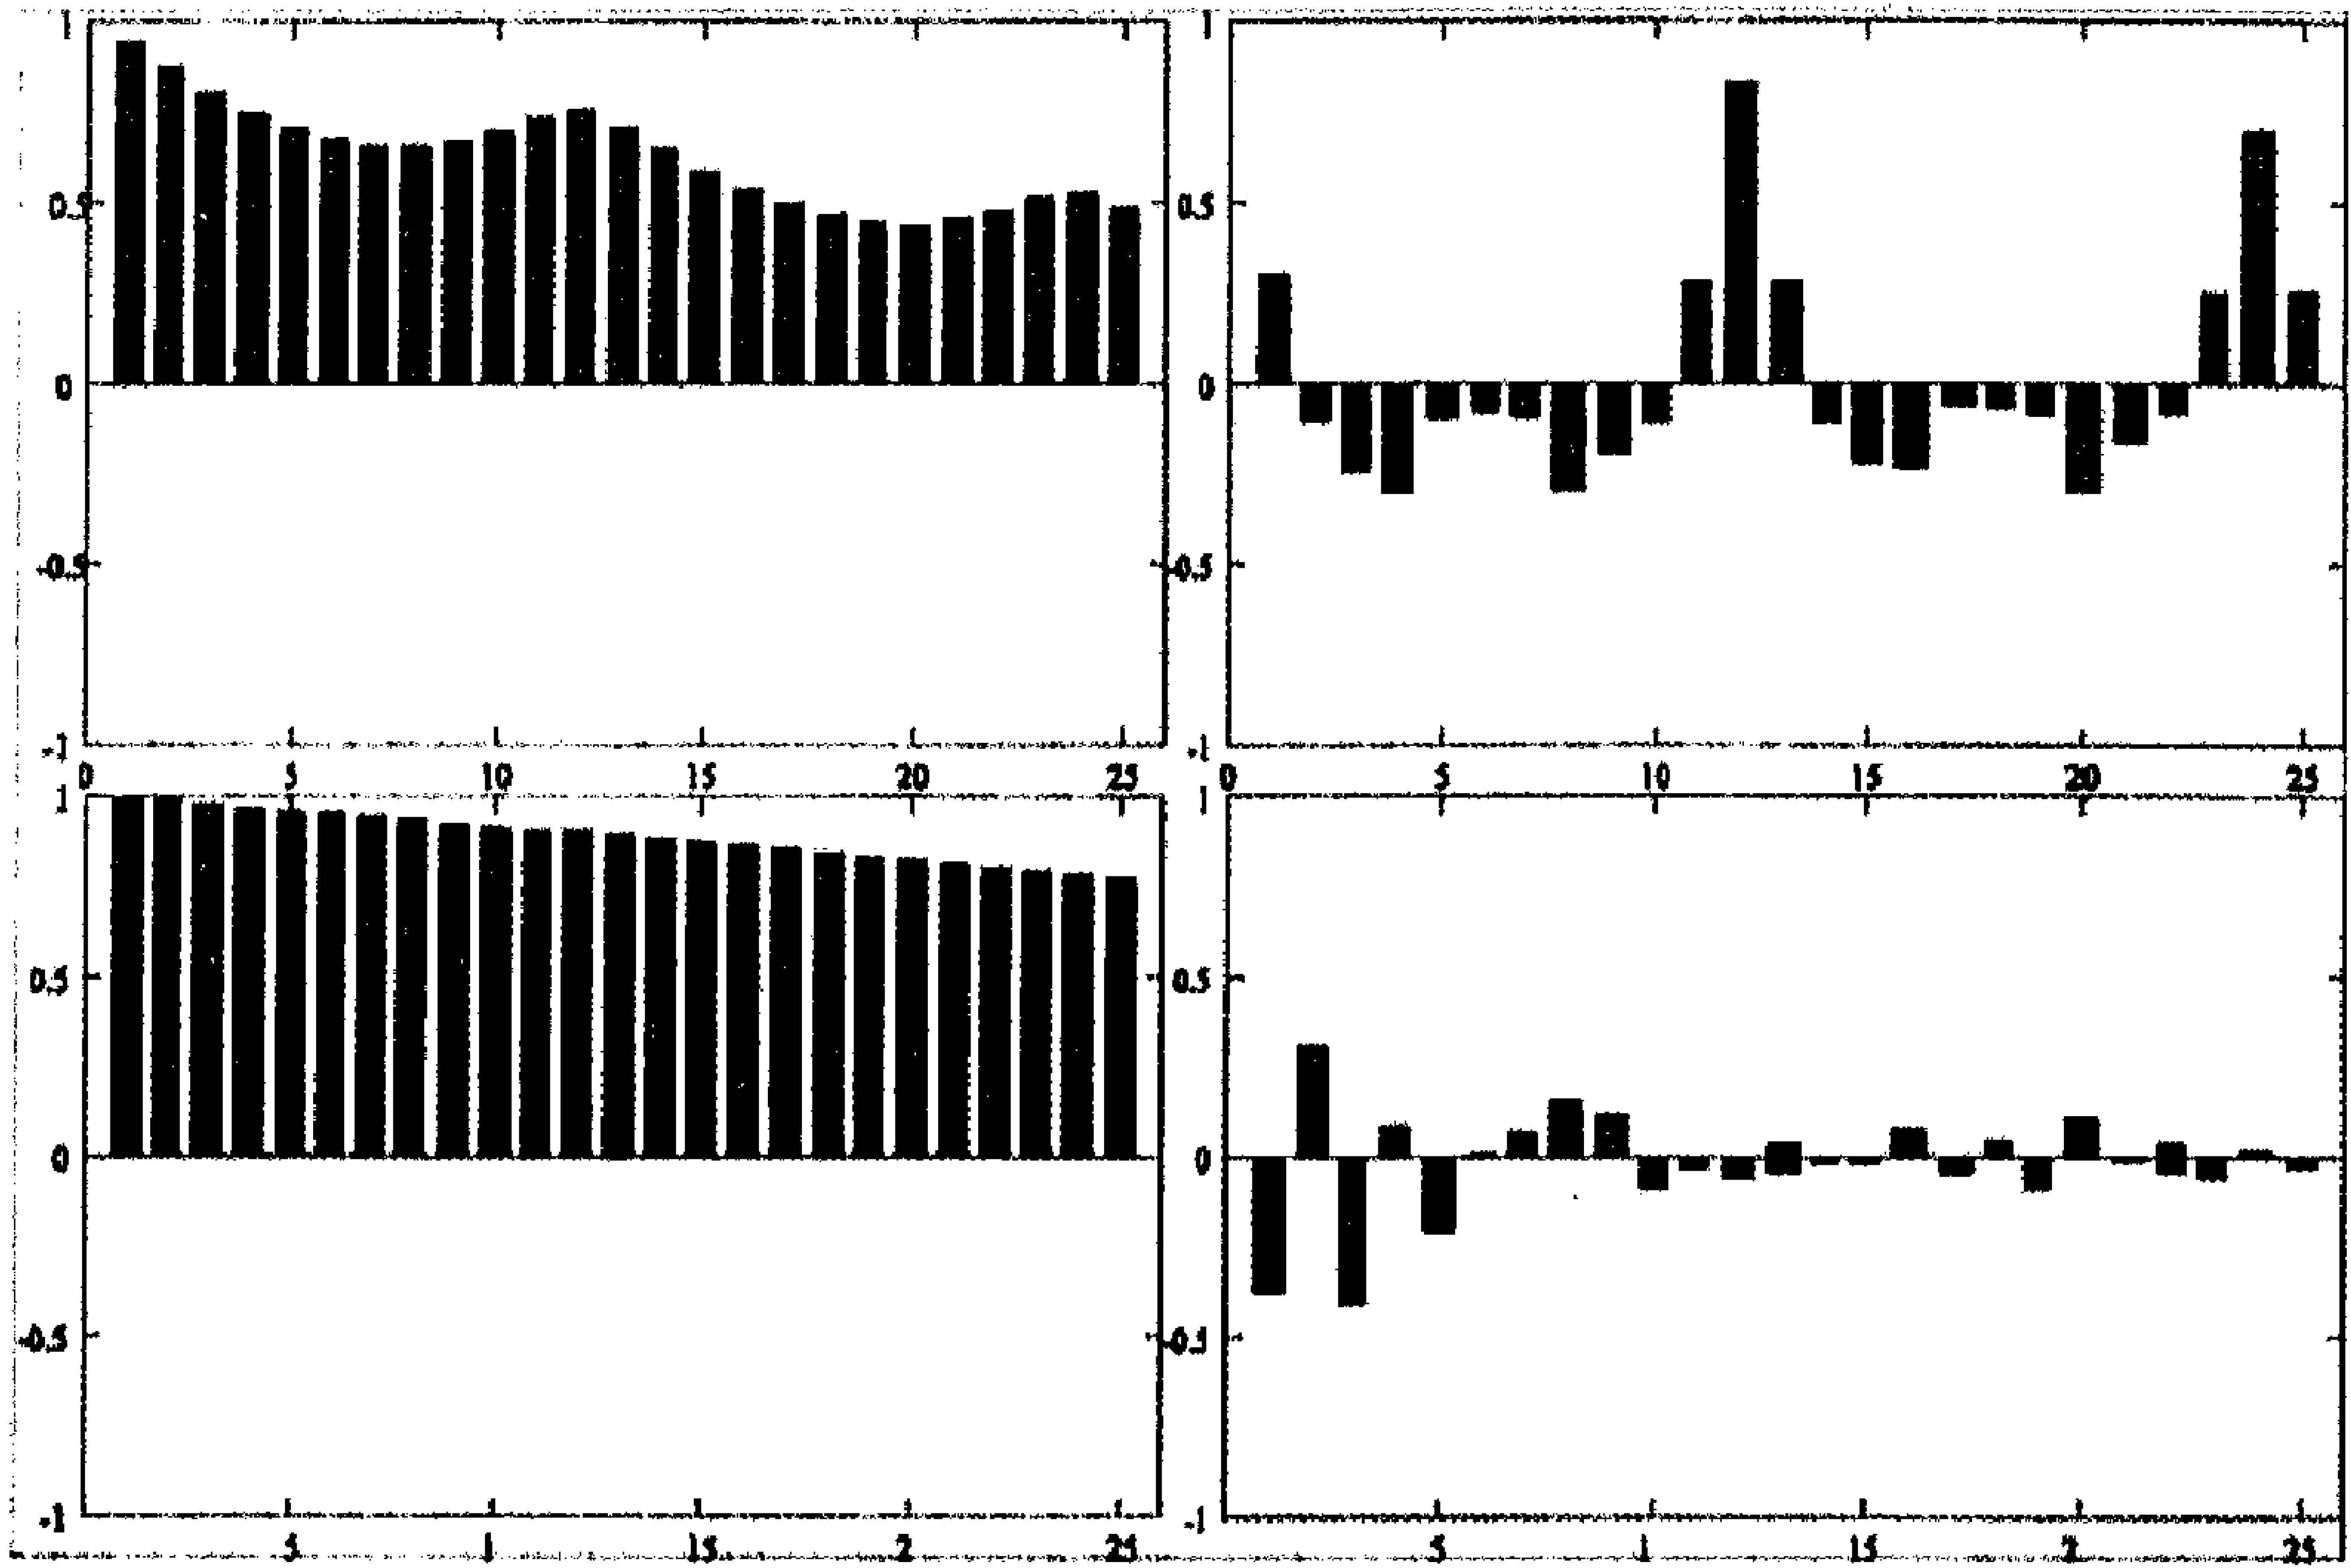
$$T_t = \beta(F_t - F_{t-1}) + (1-\beta)T_{t-1}$$

$$S_t = \gamma \frac{X_t}{F_t} + (1-\gamma)S_{t-k} \qquad (3)$$

$$\hat{X}_t = (F_{t-1} + T_{t-1})S_{t-k}$$

حيث أن: F_t، T_t وS_t ترمز إلى تخمينات التسوية والاتجاه والموسمية على الترتيب. k – الدور الموسمي. α, β, γ – بارامترات النموذج.

الشكل (1) *معاملات الارتباط الذاتي (r_k) لسلاسل نموذجية موسمية وموجهة، موسمية، موجهة، وغير موجهة (يرمز محور الفواصل للتأخيرات الزمنية K).*



تتحدد الثوابت (α ،β ،γ) عادة بإجراءات التجريب – والخطأ. عندما لا يكون هناك مركب موسمي يُستبعد البارامتر γ ويُبدل العامل S_{t-k} في المعادلة الأخيرة بالواحد.

طريقة التنبؤ الأخرى الشائعة هي منهجية Box-Jenkins (1976)، التي تمر عبر مجموعة من الخطوات: كتعريف النموذج، والتقدير البارامتري، ومصادقة (إثبات شرعية) النموذج. تعود الميزة الرئيسية لهذه الطريقة إلى الدقة في مجال أوسع من السلاسل، على الرغم من كونها أكثر تعقيداً من تقنية Holt-Winters من ناحية إمكانية الاستخدام والجهد الحسابي. يُدعى النموذج العام المعتمد على توليفة خطية من القيم السابقة (مكونات AP) وأخطاء (مكونات MA) بمُعاود ثنائي الاتجاه autoregassive integrated moving average (ARIMA)، بينما يُدعى الإصدار

الموسمي بـ SARIMA. كلا النموذجين ARIMA وSARIMA يمكن أن يُفترضا كنموذج واحد ARMA (O_A, O_M) معطى بالعلاقة التالية:

$$\hat{X}_t = \mu + \sum_{i=1}^{O_A} A_i X_{t-i} + \sum_{j=1}^{O_M} M_j e_{t-j} \qquad (4)$$

حيث أن O_A وO_M – ترمز إلى أنواع AR وMR. A_i وM_j – ترمز إلى معاملات AR و MoMR – مقدار ثابت. يتم تخمين كل من المعاملات والقيمة الثابتة للنموذج باستخدام طرق كلاسيكية (على سبيل المثال، المربعات الصغرى). تتطلب السلاسل الموجهة إيجاد الفروق بين القيم الأصلية، وقد تستخدم المنهجية أيضاً تحويلات في البيانات الأصلية (على سبيل المثال، تابع لوغاريتمي).

الشبكات العصبونية الصنعية في تنبؤ السلاسل الزمنية

النماذج الربطية هي مرشحات متأصلة من أجل التنبؤ بفضل إمكانياتها لتحمل التشويش (عدم التأثر به) واللاخطية، تكمن الفكرة الأساسية في أن تُدرّب شبكة عصبونية بالبيانات السابقة، ومن ثم تُستخدم هذه الشبكة للتنبؤ بالقيم المستقبلية. في الواقع، بدأ استخدام أنظمة التنبؤ العصبونية في أواخر الثمانينات بدراسة للعالمين Lapedes و Farber (1987) حيث تم استخدام شبكات Perceptron متعددة الطبقات للتنبؤ بسلسلة عشوائية. منذ ذلك الحين، اقتُرحت عدة بنى هندسية عصبونية مثل التوابع الشعاعية الأساسية radial-basis Functions (Shi et at., 1999)، أو الشبكات التكرارية (ULbricht, 1994)، على الرغم من أن أغلبية الدراسات تتبنى وتختار الشبكة متعددة الطبقات (Shoneburg, 1990، Tang & Fishwick, 1993، Cortez et at., 1995، Faraday & Chatfield, 1998، Huang et at. 2004). لقد ذكر في التقارير، أن نتائج تنافسات التنبؤ بمواجهة الشبكات العصبونية بالطرق التقليدية كانت إما ضعيفة (Chatfield, 1993)، أو مفضلة (Tang, Fishwick, 1993)، مشيرة إلى الحاجة لعناية كبيرة عند ملاءمة نماذج التنبؤ العصبونية.

بغرض تنفيذ نمذجة سلسلة زمنية بشبكة Perceptron متعددة الطبقات، يلزم تعيين مجموعة من حالات التدريب من البيانات باختيار نافذة زمنية منـــزلقة. في المراجع التي تناقش هذا الموضوع، تُعرّف أي نافذة منـــزلقة بالسلسلة $<K_1, K_2, ..., K_I>$ من أجل شبكية بـــ I دخل وتأخيرات زمنية. على سبيل المثال، ليكن لدينا سلسلة شهرية معطية بالتسلسل التالي: ...،8كانون الثاني، 11شباط، 16آذار، 20نيسان، 17أيار، 22حزيران. عند افتراض نافذة زمنية من <1, 2, 4>، فإن حالات التدريب الأخيرة التي يمكن أن تُعيّن في شهر حزيران هي: 8، 16، 20 ← 17 و11، 20، 17 ← 22.

في هذا العمل، سيتم اختيار وتبني طبولوجية متصلة كلياً بطبقة خفية واحدة، وانحياز، واتصالات مختصرة مباشرة من الدخل إلى عقد الخرج (الشكل 2). لتحسين اللاخطية، يُطبق تابع التنشيط المنطقي (اللوجستي) Logistic على العقد الخفية، بينما يستخدم التابع الخطي Linear بدلاً عنه في عقدة الخرج. لقياس مجال نواتج الخرج، طالما أن التابع اللوجستي يمتلك مجال خرج من [0، 1]. تتفادى هذه البنية الهندسية المُختارة غالباً من قبل جماعة التنبؤ (Faraday & Chatfield, 1998; Huang et at., 2004) الحاجة لإجراءات ترشيح وتنقية (على سبيل المثال، إعادة التقييس) التي قد تؤدي إلى ارتفاع في ضياع المعلومات. وبالتالي، يُعطى النموذج العام بالصيغة التالية.

$$\hat{X}_t = \omega_{out,0} + \sum_{t=1}^{I} X_{t-x_t}\omega_{out,i} + \sum_{j=I+1}^{out-1} f\left(\sum_{i=1}^{I} X_{t-k_i}\omega_{j,i} + \omega_{j,0}\right)\omega_{out,i} \qquad (5)$$

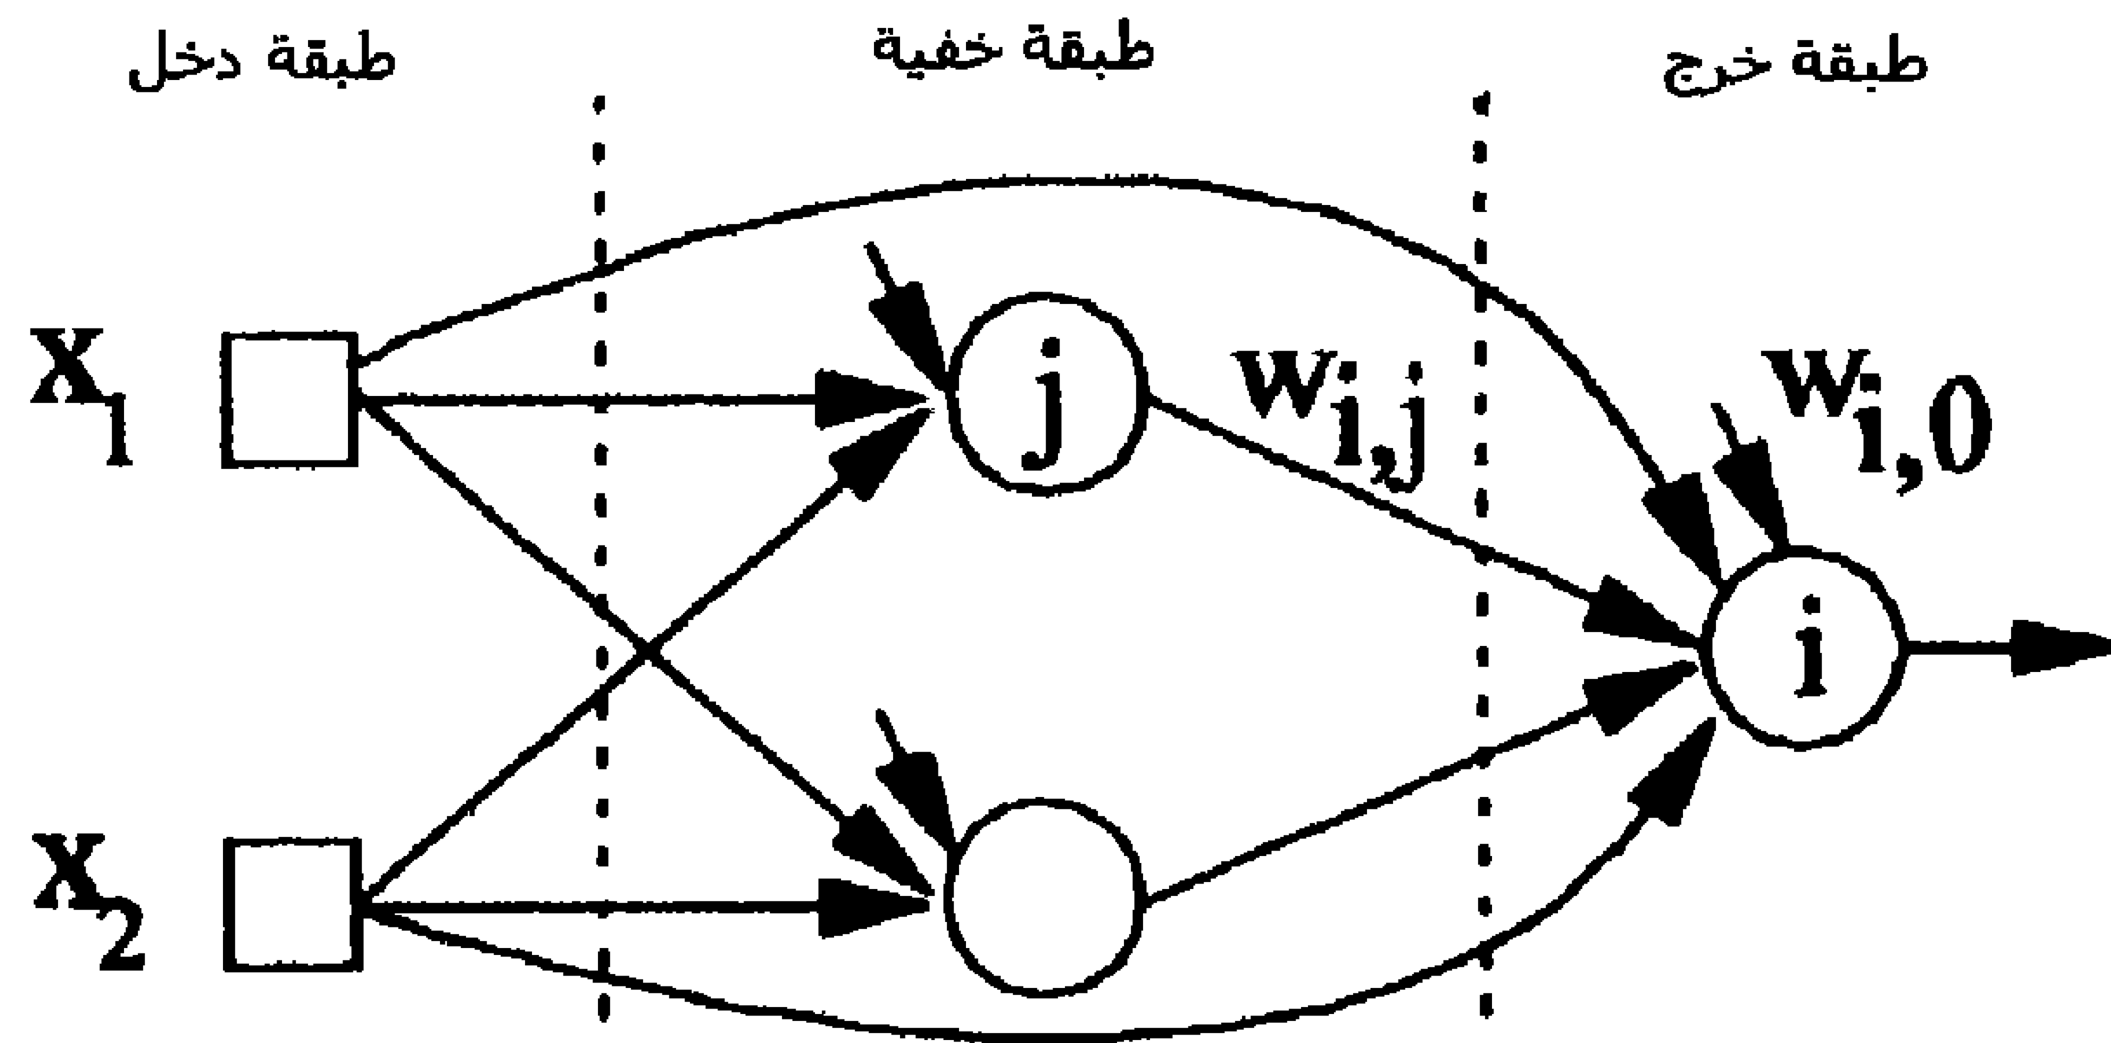
حيث أن $\omega_{i,j}$ – ترمز إلى وزن الاتصال من العقدة j إلى العقدة i (إذا كان j = 0، عندئذ يكون اتصال انحياز)، Out – ترمز إلى عقدة الخرج. f – التابع اللوجستي $\left(\frac{1}{1+\bar{e}^{x}}\right)$. I – عدد عصبونات الدخل.

بيانات السلاسل الزمنية

تم اختيار 10 سلاسل من مجالات ومصادر مختلفة من أجل التجارب المنفذة في هذا العمل. كان المغزى هو اختيار مجموعتي بيانات لتمثيل كل من الفئات الرئيسية الخمسة التالية: موسمية وموجهة، موسمية، موجهة، غير موجهة، وعشوائية. باستثناء البيانات المُولّدة بشكل اصطناعي (تربيعية أو من الدرجة الثانية quadratic، وhenon)، فإن كافة السلاسل متوفرة وموجودة في مستودع مكتبة بيانات السلاسل الزمنية Time Series Data Library المحافظ عليه من قبل العالمين Akram وHyndman (2005) والذي يحتوي على أكثر من 800 سلسلة.

النوع الأول – السلاسل الموسمية والموجهة – شائع جداً في البيانات الشهرية كالسلاسل الموجودة في المبيعات. إحدى الأمثلة على ذلك – هي مجموعة بيانات المسافرين التي تمثل عدد المسافرين الدوليين (بالآلاف) لشركة خطوط نقل جوية من عام 1949 إلى عام 1969. وهي سلسلة مشهورة تم تحليلها في دراسة كلاسيكية للعالمين Box (1976) و Jenkins تظهر سلسلة الورق Paper نفس الخصائص، والتي قُدمت بتقرير عن مبيعات الصناعة الفرنسية لورق الطباعة والكتابة (بآلاف الفرنكات) من كانون الثاني 1963 إلى كانون الأول 1972 (Makridakis et at, 1998).

الشكل (2) *شبكة Perceptron متعددة الطبقات متصلة كلياً بدخلين وخليتين عصبونيتين في الطبقة الخفية، وخرج واحد وانحياز واتصالات مختصرة.*



تتضمن مجموعات البيانات ذات المكونات الموسمية فقط على سلسلة الوفيات deaths وسلسلة درجات الحرارة max temp. الأولى متعلقة بعدد الوفيات الشهرية والإصابات الخطيرة في حوادث الطرق البريطانية من كانون الثاني عام 1969 وحتى كانون الثاني عام 1983 (Harvey, 1989)، أما الأخيرة فهي سلسلة أرصاد جوية تحتوي على درجة الحرارة العظمى المتوسطة الشهرية (بدرجات سيليزوس) المُقاسة في ميلبورن – استراليا – من كانون الأول عام 1971 وحتى كانون الثاني عام 1990 (Hyndman & Akram, 2005).

بالنسبة للسلاسل الموجهة فقد تم تقديمها لأول مرة في دراسة للعالمين Box و Jenkins (1970). تحتوي مجموعة بيانات الأسعار Prices على بيانات مالية نسبةً على أسعار إقفال أسهم IBM اليومية المُقاسة من 17 أيار عام 1961 وحتى 2 تشرين الثاني عام 1962. تشير المجموعة الأخرى إلى قراءات درجات الحرارة (المُجمعة كل دقيقة) لعملية كيميائية Chemical.

أخذت السلاسل غير الموجهة من مجال الفيزياء. تم تجميع عدد البقع الشمسية sunspots السنوية من عام 1700 وحتى عام 1999، التي اُستخدمت بشكل عام لاختبار تقنيات تنبؤ لا خطية (Tong, 1983). تحتوي بيانات Kobe – التي هي أيضاً لا خطية – على التسجيلات الـ 200 الأولى لراسمة الزلازل المأخوذة من زلازل Kobe والمُسجلّة في جامعة تازمانيا - استراليا - في 16 كانون الثاني عام 1995 ابتداءً من 20:56:51 بتوقيت غرينتش (Hyndman & Akram, 2004).

أخيراً، خُلقت السلسلتين الأخيرتين اصطناعياً بتوليد 200 نقطة باستخدام صيغ عشوائية أي (Peitgen, Jürgens, & Saupe, 1992):

- تربيعية (من الدرجة الثانية quadratic) $x_t = a\,x_{t-1}\,(1 - x_{t-1})$ حيث $a = 0$ و$X_0 = 0.2$
- $henon \leftarrow x_t = 1 - ax_{t-1}^2 + bx_{t-2} + N(0.0,0.1)$، حيث $a = 1.4$، $b = 0.3$، $x_0 = 0.11$، ويرمز العامل الأخير لضجيج غاوس بانحراف معياري 0.1.

يبين (الجدول 1) خلاصة لأكثر السمات المتعلقة بـــ 10 مجموعات بيانات، فيما يظهر (الشكل 3) هذه السمات في منظور بياني. من أجل تنفيذ التجارب، قُسمت كل سلسلة إلى مجموعة تدريب تحتوي على قيم الـــ 90% الأولى، ومجموعة اختبار بالـــ 10% الباقية (يبين عمود الحجم طول السلسلة). تُستخدم مجموعة التدريب فقط من أجل اختبار النموذج وأَمْثَلة البارامترات، بينما تستخدم مجموعة الاختبار لمقارنة الطريقة المقترحة بالطرق الأخرى.

الجدول (1) السمات الرئيسية للسلاسل الزمنية المستخدمة في التجارب

السلسلة	النوع	الحجم	الوصف
مسافرون passengers	موسمية وموجهة	144	مسافرو خطوط النقل الجوية شهرياً
ورق paper	موسمية وموجهة	120	مبيعات الورق الشهرية
وفيات deaths	موسمية	169	الوفيات/الإصابات على الطرق البريطانية شهرياً
درجات حرارة عظمى maxtemp	موسمية	240	درجة الحرارة العظمى في ميلبورن
كيميائية chemical	موجهة	198	قراءات التركيز الكيميائية.
أسعار prices	موجهة	369	أسعار إقفال أسهم IBM اليومية
البقع الشمسية sunspots	غير موجهة	289	عدد بقع ولف الشمسية السنوية
kobe	غير موجهة	200	مرسمة الزلازل لزلزال kobe
تربيعي quadratic	عشوائية	200	تابع نقل تربيعي
henon	عشوائية	200	تابع نقل من النوع henon

الطريقة التجريبية لاختيار النموذج

متى تكون السلسلة الزمنية المنمذجة بالشبكات العصبونية قضية حاسمة لاختيار النموذج؟ بمعنى، ما هي النافذة الزمنية المنـــزلقة الأفضل والبنية الهندسية العصبونية الأحسن لسلسلة ما مفروضة؟ يمكن أن يؤدي كلا الخيارين إلى تأثير عالٍ على أداء التنبؤ.

ستزود نافذة صغيرة معلومات نادرة إلى الشبكة، بينما قد يزيد عدد كبير من التأخيرات الزمنية الانتروبيا التي تؤثر على التعلّم. على سبيل المثال، تستخدم نماذج الـــ SARIMA في أغلب

الأحيان فقط التأخيرات <1, 12, 13> من أجل السلاسل الموجهة الموسمية الشهرية. بشكل مشابه، فإن شبكة ببضع عصبونات خفية ستكون ذات إمكانيات محدودة للتعلّم. وعلى النقيض من ذلك، فإن استخدام عدد زائد عن العقد الخفية سيؤدي إلى فرط ملاءمة بيانات التدريب.

الطريقة الإحصائية لاختيار النموذج هي دراسة نماذج ترشيح مختلفة تُقيّم وفقاً لتخمين عام. وقد تم تطوير عدة أجهزة تخمين مرهقة حسابياً (Sarle, 1995). يكمن بديل معقول بإعاقة تعقيد النّموذج باستخدام إحصائيات بسيطة كمعيار بواسون للمعلومات BIC (Schwarz, 1978):

$$BIC = N\,L_n\left(\frac{SSE}{N}\right) + P\,Ln(N) \qquad (6)$$

حيث أن: N – ترمز إلى عدد حالات التدريب. P – عدد البارامترات.

على الرغم من أن هذا المعيار قد اُقترح أساساً من أجل النماذج الخطية، فإنه يُوصى به أيضاً من أجل التقدير العصبوني (Faraday & Chatfield, 1998). وعندما يطبق على شبكات عصبونية، فإن عدد البارامترات P يساوي عدد أوزان الاتصالات.

بغرض التوصل إلى بعض الاستنتاجات التمهيدية، سيتم اختبار اختيار نموذج تنقيبي، وسوف تُستخدم أربعة قواعد لتوليد نوافذ زمنية منزلقة، هي (Cortez et at., 1995):

1. استخدام كافة التأخيرات الزمنية من 1 إلى قيمة عظمى مفروضة m: <1, 2, ..., m> (أخذت m مساوية لـــ 13، وهي القيمة التي اُعتبرت كافية للإحاطة بالتأثيرات الموجهة والموسمية الشهرية).
2. استخدام كافة التأخيرات التي تحتوي على قيم ارتباط ذاتي فوق عتبة مفروضة (أُخذت مساوية لـــ 0.2)
3. استخدم أربعة تأخيرات بالارتباطات الذاتية الأعلى.
4. استخدام معلومات التفكيك أي:

- <1, k, k + 1> ← إذا كانت السلسلة موسمية (بدور k) وموجهة.
- <1, k> ← إذا كانت السلسلة موسمية.
- <1> ← إذا كانت السلسلة موجهة.

استخدمت عدة شبكات Perceptrons متعددة الطبقات بعدد عقد خفية (H) تتراوح بين 0 إلى 13 لسبر كافة النوافذ لكل سلسلة في (الجدول 1) وأُتخذت خوارزمية RPROP للتدريب

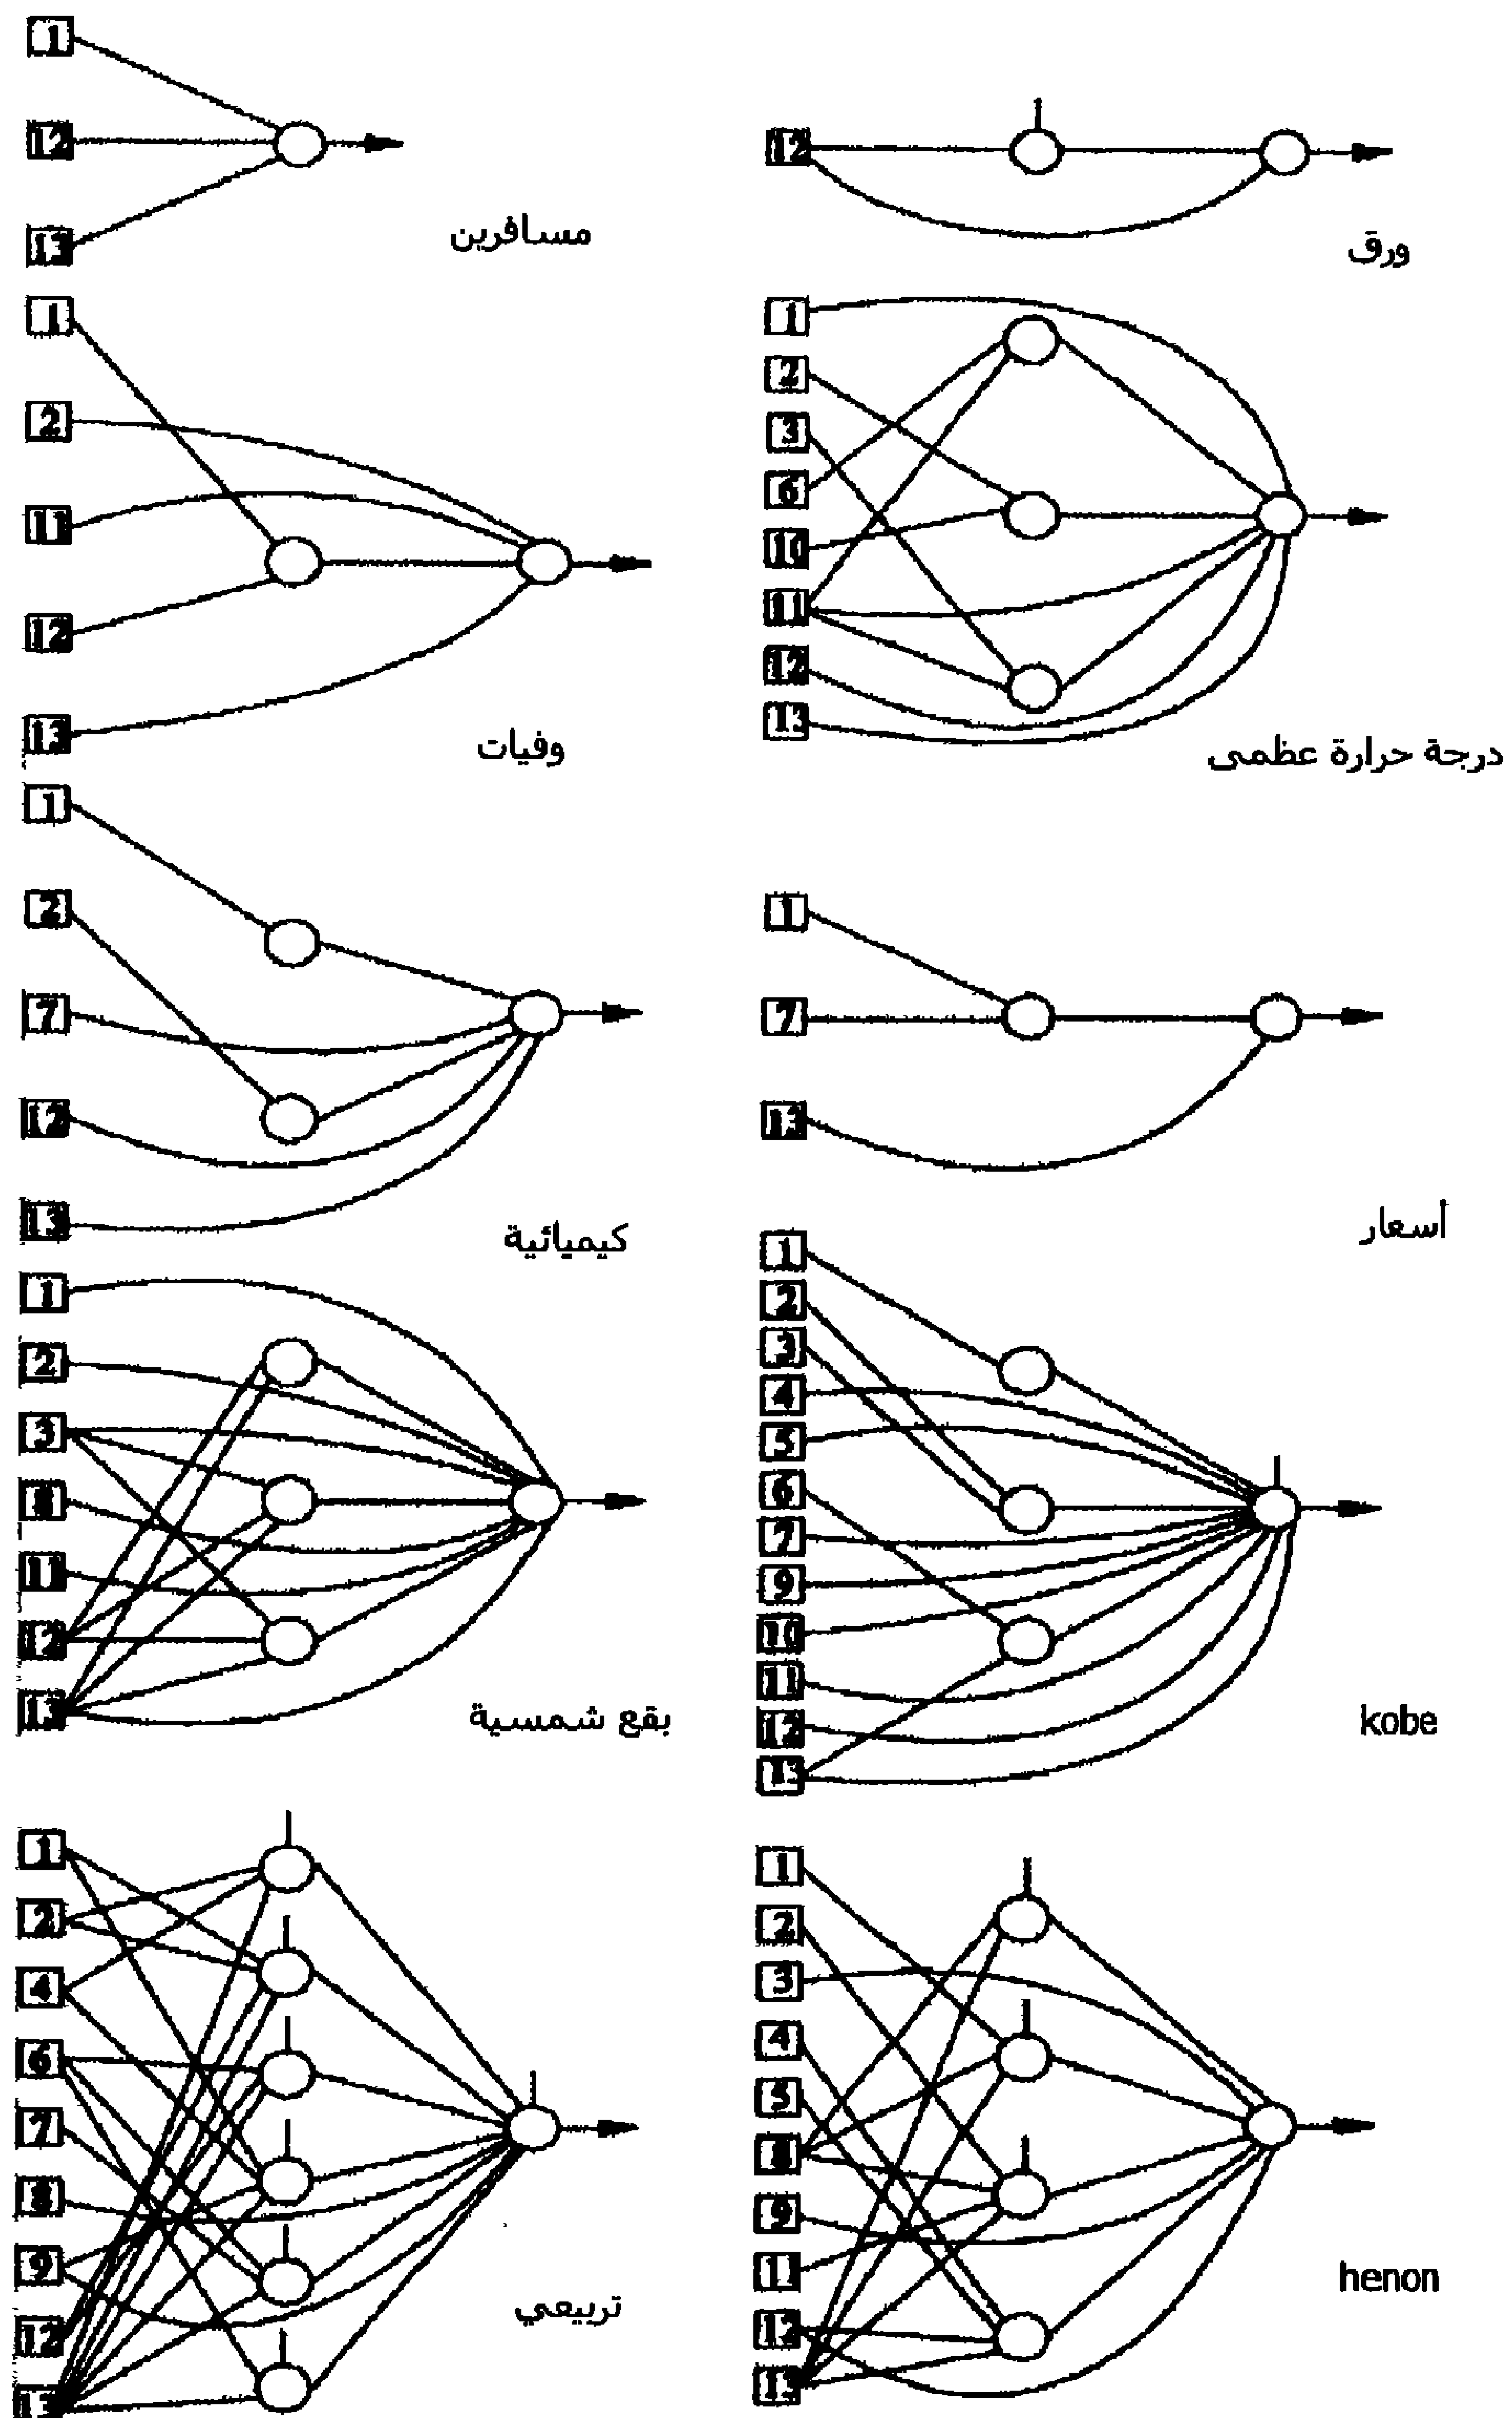
(Riedmiller, 1994)، بما أنها تسمح بتقارب سريع، وتتوقف عندما يقترب ميل الخطأ من الصفر أو بعد 1.000 دورة. أثناء تلك العملية، تُقدم حالات التدريب في ترتيب زمني إلى الشبكة بغرض المحافظة على التعاقب المرتب زمنياً للأنماط طالما أنها غير مستقلة. تم إجراء كافة الاختبارات المذكورة، في هذا العمل باستخدام بيئات برمجة مطورة في ++C (Neves, Rocha, Rodrigues, Biscaia, & Alves, 1999). وكمثال، سيتم شرح المنهجية المستخدمة لسلاسل البقع الشمسية بالتفصيل (الجدول 2). وبغرض تبسيط الشرح، تم عرض بضعة تشكيلات فقط في هذا الجدول. وقد أعطيت النتائج في الأعمدة الأربعة الأخيرة بمعدل 30 تشغيل للبرنامج، في حين أن الأوزان الابتدائية قد وُلدّت عشوائياً، وأظهرت 90% من مجالات الثقة بالنسبة لأخطاء التنبؤ (Flexer, 1996). تشمل الإحصائيات المحسوبة على عدد الأوزان (p)، وتخمينات التدريب (BIC و$RMSE_t$)، وخطأ التنبؤ ($RMSE_f$). في هذا المثال، لم تُطبق القاعدة 4، باعتبار أن سلسلة البقع الشمسية ليست موسمية ولا موجهة.

الجدول (2) طريقة اختيار النموذج التنقيبي المطبق على سلسلة البقع الشمسية

النافذة الزمنية	العقد الخفية	الأوزان	التدريب		التنبؤ
	(H)	(P)	$RMSE_t$	BIC	$RMSE_t$
	0	14	14.7	1404	0.1 ± 18.2
قاعدة 1: <1, 2, ..., 13>	6	104	11.6	1784	0.7 ± 20.5
	13	194	9.0	2155	0.8 ± 20.2
	0	5	14.8	1369	0.1 ± 17.9
قاعدة 2: <1, 2, 9, 10, 11, 12>	5	47	11.5	1467	0.6 ± 17.0
	13	111	9.4	1717	0.8 ± 19.0
	0	5	15.1	1369	0.0 ± 18.0
قاعدة 3: <1, 2, 10, 11>	1	11	14.1	1368	0.3 ± 17.8
	8	53	10.7	1464	0.5 ± 19.4

يحتوي نموذج خطأ التدريب الأفضل ($RMSE_t$) على عدد كبير من البارامترات والتوافقات الزائدة. يؤدي استخدام عقد خفية أكثر إلى قيم تدريب RMSE أخفض. مع ذلك، عندما تخصص شبكة ما، فإن أداءها ينخفض عادة. وعلى العكس، فإن معيار BIC يعمل بشكل أفضل باختيار شبكة تعطي واحدة من أفضل التنبؤات (العمود $RMSE_f$). ظهر هذا السلوك بثبات في كافة السلاسل.

الشكل (3) *السلاسل الزمنية العشرة للجدول (1) في منظور زمني*



يبين (الجدول 3) الشبكات العصبونية الأفضل (بقيم BIC أخفض) مُعطاة بالطريقة التجريبية. كما هو متوقع، يقترح المعيار نوافذ زمنية صغيرة ونماذج خطية (بدون عقد خفية) لكافة السلاسل الخطية. على أية حال، فإن إحصائية BIC تفضل أيضاً نماذج بسيطة (بعقدة خفية واحدة أو بدون) للسلاسل اللاخطية (سلسلة kobe والبقع الشمسية). على سبيل المثال، أُنتجت أفضل التوقعات لسلسلة البقع الشمسية كشبكة بخمس عقد خفية، على الرغم من أنه قد تم الحصول عليها خلال قيمة عالية لـــ BIC بسبب وجود عدد زائد من الأوزان (الجدول 2).

الجدول (3) نماذج التنبؤ العصبونية الأفضل المُعطاة بالطريقة التنقيبية.

السلسلة	النافذة الزمنية	العقد الخفية (H)	الأوزان (P)	التنبؤ RMSEf
مسافرون	<1, 12, 13>	0	4	0.2 ± 18.4
ورق	<1, 12, 13>	0	4	0.2 ± 51.6
وفيات	<1, 11, 12, 13>	0	5	1 ± 134
درجة حرارة عظمى	<1, 11, 12, 13>	0	5	0.01 ± 0.90
كيميائية	<1, 2>	0	3	0.01 ± 0.40
أسعار	<1>	0	2	0.01 ± 7.49
بقع شمسية	<1, 2, 10, 11>	1	11	0.3 ± 17.8
kobe	<1, 2, ..., 13>	0	14	4 ± 557
تربيعي	<1, 2, ..., 13>	9	149	0.02 ± 0.06
henon	<1, 2, ..., 13>	2	44	0.05 ± 0.35

تطرح استراتيجية اختيار النموذج التنقيبي بعض القيود، فمن ناحية المعيار BIC الذي يتبنى شبكات متصلة كلياً، يبدو أنه يتحيز لشبكات بعقد خفية. علاوة على ذلك، فإن قواعد النافذة المنزلقة تعتمد على قيم الارتباط الذاتي التي تقيس فقط الارتباط الخطية، وبهذا لن تكون ملائمة للسلاسل اللا خطية. سيتم في القسم التالي اقتراح طريقة تطويرية لحل هذه العوائق.

طريقة تطويرية لاختيار النموذج

قُدمت الخوارزمية الوراثية أولاً من قبل العالم Holland (1975). ومنذ ذلك الحين طور مفهوم المتغيرات الحسابية المتعددة التي تشترك بمجموعة من السمات العامة. يوجد عدد من الحلول الممكنة (السلاسل) الفردية لمشكلة ناشئة آنياً (مجتمع). تُرمّز كل سلسلة فردية بسلسلة (صبغيات) أو رموز (مورثات) مأخوذة من أبجدية معروفة جيداً. تُحدد كل سلسلة فردية بقيمة

عددية (ملائمة) تمثل لياقة أو مناسبة الحل. ويُبدل جزء من السلاسل الفردية خلال كل توليد بالنسل المُولّد بتطبيق معاملات وراثية كالتصالب والطفرة، بغرض خلق حلول جديدة (تكاثر). العملية بالكامل هي عملية تطويرية، حيث تمتلك السلاسل الفردية الأصلح فرصاً أكبر للبقاء.

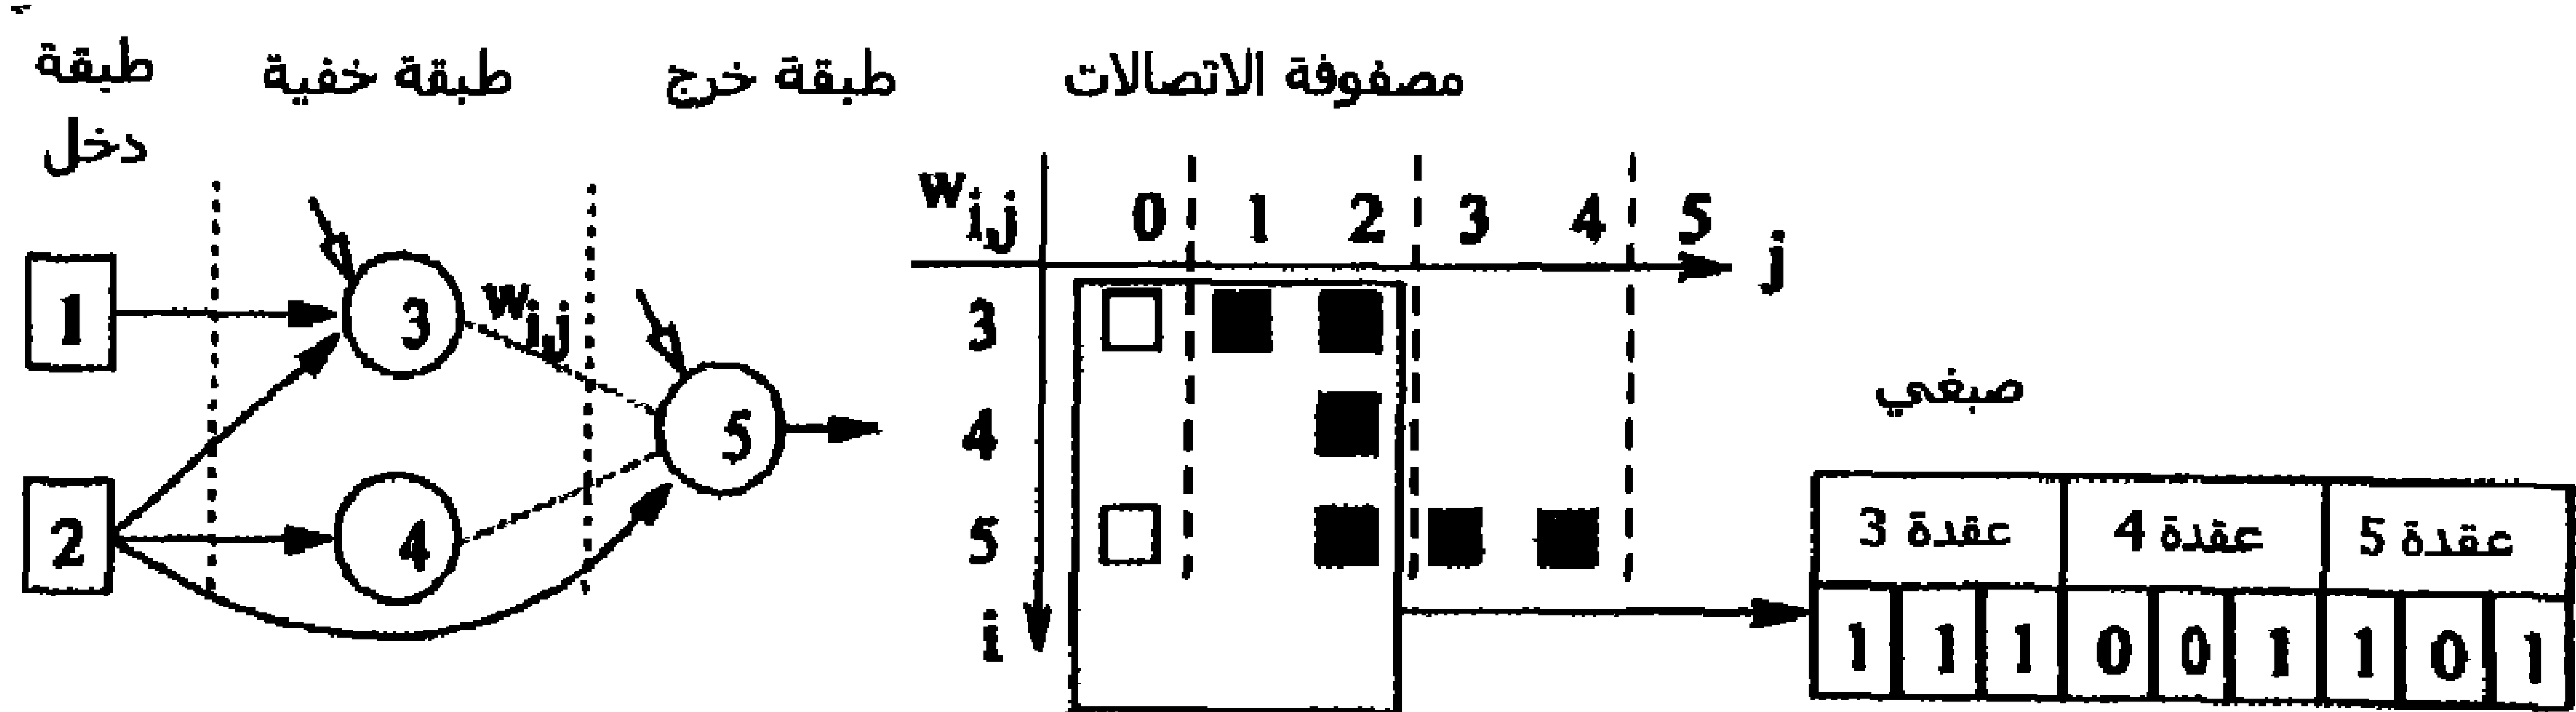
شكلت الأمْثلة التطويرية للطبولوجيات العصبونية أرضاً خصبة للبحث في السنوات القليلة الماضية (Yao, 1999).تختلف النماذج المقترحة في قضيتين رئيسيتين: تابع الملاءمة وتمثيل الشبكة العصبونية. بالنسبة للموضوع الأول، فإن الطريقة المألوفة أكثر هي دراسة قياس الخطأ على مجموعة إثبات مستقلة. من جهة أخرى، فقد تم توجيه مخطط التمثيل ببديلين هما: ترميزات مباشرة وغير مباشرة. تُرمّز الأولى كافة التفاصيل الطبولوجية (الأوزان والاتصالات) وأصبحت الطريقة الأكثر استخداماً، طالما أنها أكثر كفاءة وسهلة التطبيق. بينما تمثل الثانية البارامترات الأكثر أهمية، أو تحدد استعمال قواعد البناء. أحد الأمثلة الممتعة لمخطط غير مباشر مُعطى بعمل العالم Gruau (1992)، حيث تُستخدم مجموعة من قواعد اللغة لإنشاء البنية الهندسية العصبونية. الترميز المباشر قابل للتوجه ومعقول بيولوجياً أكثر، وهو يفضل الشبكات المنتظمة. على أية حال، بما أنه تم اعتبار شبكات معيارية فقط (Modular Networks). فإن فضاء البحث من أجل الطبولوجية الأفضل يكون مقيداً، وأظهرت هذه الطريقة بعض العوائق في مشاكل العالم الحقيقي (Siddiqi & Lucas, 1998).

عند تصميم شبكات Perecptrons متعددة الطبقات لتنبؤ السلاسل الزمنية، فإنه من الشائع استخدام إجراءات التجريب والخطأ، كاختبار عدة توليفات لعقد خفية (Tang & Fishwick, 1993، Faraday & Chatfield, 1998). يجسد استخدام التصميم التطوري محاولة بديلة لاختيار الطبولوجية العصبونية لسلسلة زمنية. في الحقيقة، تم اقتراح عدة شبكات عصبونية تطويرية تستخدم معظمها تمثيلاً بارامترياً غير مباشر، وعوامل ترميز كعدد المُدخلات والعقد الخفية، والأوزان الابتدائية، وتوابع التنشيط، أو حتى معدلات التعلّم (Chen & Lu, 1999، Falco, Cioppa, Lazzet ta, Natale, & Tar, 1998). على أية حال، من وجهة نظر اختيار النموذج، يبدو بأن ضبط اتصالية الشبكة Perceptron متعددة الطبقات يكون أكثر أهمية.

تم في هذا العمل اقتراح شبكة عصبونية تطويرية مبتكرة باستخدام تمثيل ثنائي مباشر. بما أن التجارب السابقة – قد أظهرت بأن السلاسل الزمنية نُمذجت غالباً بشبكات صغيرة، فإن هذا الترميز سيمنع الطبولوجيات من النمو الكبير جداً، والذي هو أيضاً أكثر كفاءةً وفعالية.

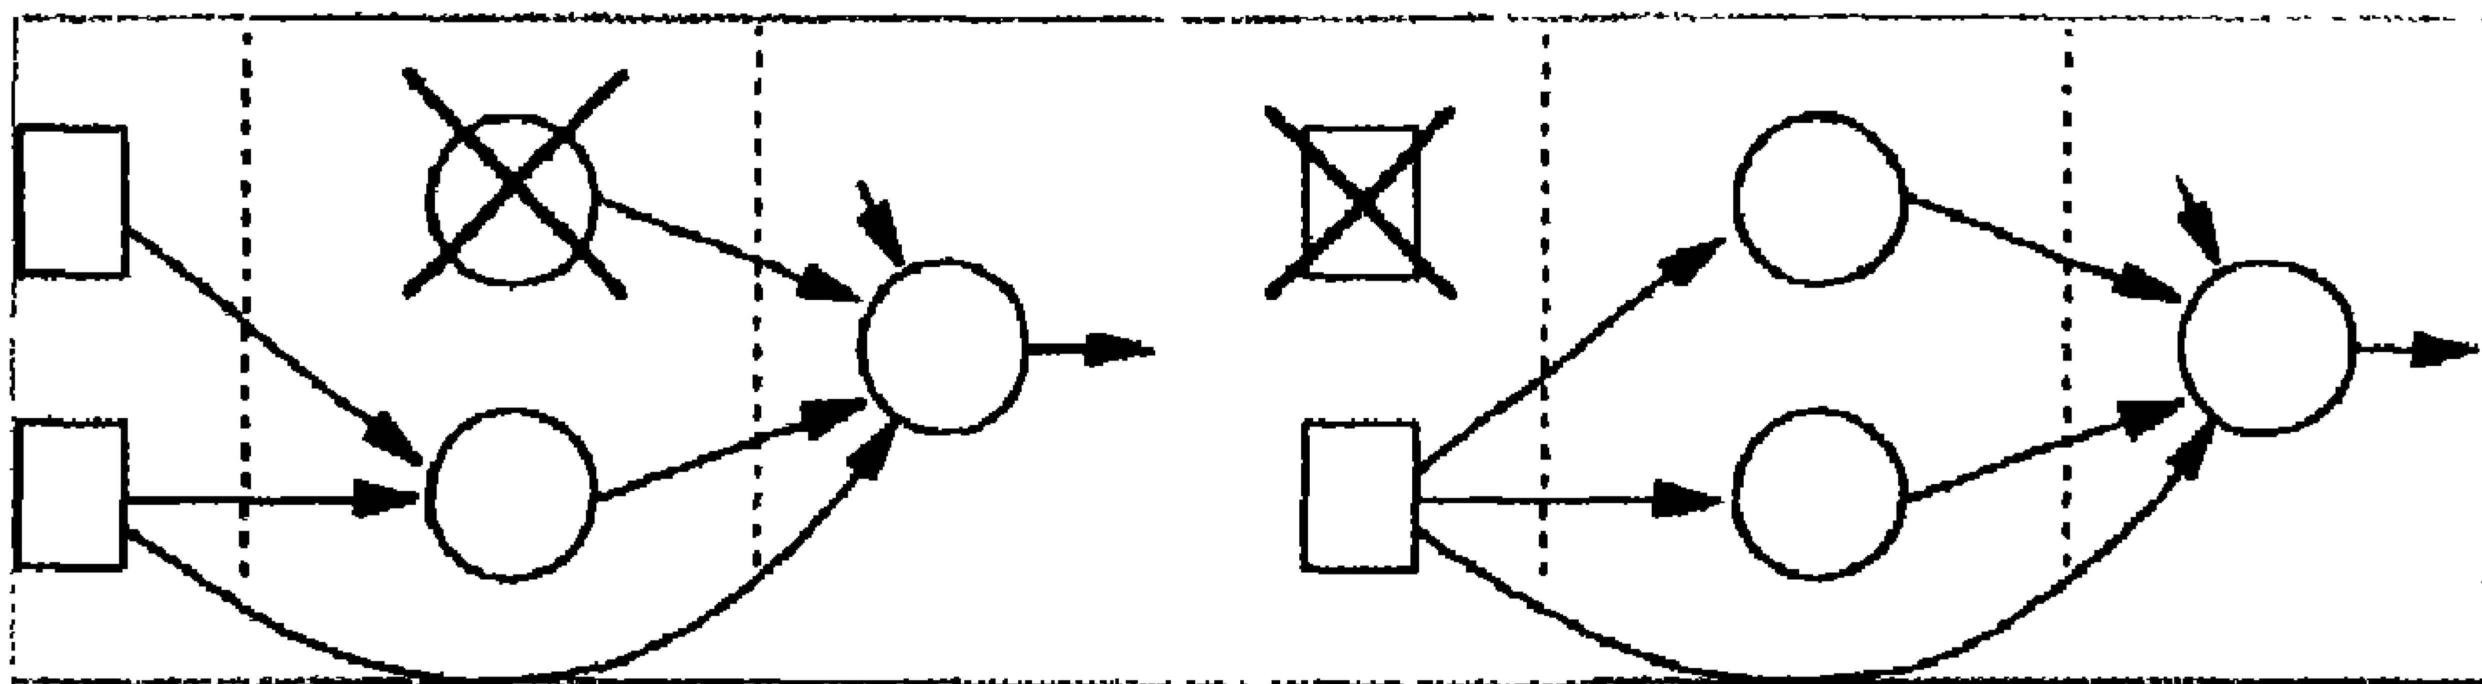
وبهذا، تمثل كل مورثة اتصالاً محتملاً، فإذا كانت قيمتها 1 يكون الاتصال الموافق موجوداً، وإلا فإنها لا تُؤخذ بالاعتبار. تكون الاتصالات بين العقد الخفية وعقدة الخرج موجودة أيضاً، طالما أن هذه الاستراتيجية تُحسن تكوين شبكات صحيحة. يوضح (الشكل 4) كيفية عمل مخطط الترميز.

الشكل (4) *استعراض عملية الترميز لبنية هندسية عصبونية مُعطاة.*



بفرض لدينا قيمة عظمى للمدخلات I وللعقد الخفية H، وللانحياز وللاتصالات المختصرة، فيكون حجم الصبغي مُعطى بالجداء التالي (1 + H) (1 + I). سوف يحدث تشذيب العقدة الخفية عندما لا يوجد اتصالات من عقد الدخل، وسيحدث تشذيب عقدة الدخل عندما لا يكون هناك أي خرج لعقدة دخل (الشكل 5). يسمح هذا بتمثيل كامل معرفاً فضاء بحث، يحتوي على كافة الطبولوجيات العصبونية ابتداءً من شبكة Perceptron الخطية الأبسط وحتى الشبكة المتعددة الطبقات المتصلة كلياً، وصولاً أيضاً إلى أي مجموعة جزئية من عقد الدخل (المنفذة لاختيار السمات).

الشكل (5) *مثال لتشذيب عقدة خفية (يسار) وتأخير زمني مُدخل (يمين).*



بالنسبة لتابع الملائمة، يؤدي استخدام مجموعة إثبات وتحقّق إلى ضياع معلومات، طالما أُخذت بالاعتبار مجموعات تدريب أصغر. علاوة على ذلك، فإن الطبيعة الزمنية لوسط السلاسل الزمنية تحسن هذا التأثير، باعتبار أن حالات الإثبات نموذجياً أكثر حداثة في بيانات التدريب. وكخيار بديل يمكن استخدام المعيار BIC الذي يقدم ميزة بساطة الحسابات اللازمة، بينما يزيد ضغط الاختيار في مصلحة البنى الهندسية الأبسط متبعاً مبدأ آلة حلاقة أوكهام Ockham's razor.

تم تعيين مورثات المجتمع الابتدائي عشوائياً ضمن الأبجدية {0, 1}. وأُخذ العدد الأعظم للمدخلات n والعقد الخفية (H) مساوياً لـــ 13 و6 - باعتبار أن التجارب السابقة قد فضلت الشبكات الصغيرة – مؤديةً إلى صبغي بـــ 98 مورثة. بما أن الخوارزمية الوراثية تعمل كإجراء أَمْثَلة ثانٍ (مستوى عالٍ)،

فإن وضع بارامتراتها لا يعتبر حاسماً. بالعودة إلى التجارب التمهيدية، فقد وضع حجم المجتمع مساوياً 100 سلسلة فردية بجعل معامل التصالب بنقطتين (Two-point crossover) مسؤولاً عن توليد 80 % من النسل، بينما كان معامل الطفرة البتي bit mutation مسؤولاً عن بقية النسل. وفق الطريقة المقترحة، يمكن أن تُعرّف كتل بناء رئيسية بمجموعة من الاتصالات التي تغذي عصبون طبقة خفية. لذلك، لتجنب تصدعه، تم تقييد نقاط قطع التصالب (Opitz & Shavlik, 1994). نُفذ إجراء الاختيار بتحويل قيمة الملاءمة إلى مرتبتها في المجتمع، ومن ثم تطبيق مخطط عملية روليت (دحرجي). يُوقف الإجراء التطويري بعد عدد ملائم من الأجيال G_{max} – وهنا كان مساوياً لـــ 200 – حالما يتم ايجاد السلاسل الفردية الأفضل في أجيال أسبق. أخيراً، تم تطبيق 30 تشغيل للبرنامج لأفضل طبولوجية متضمنة. بنية الخوارزمية التطويرية موصوفة بالكود التالي:

بداية R

بداية الزمن $(t = 0)$

توليد مجتمع التنبؤ العصبوني الابتدائي (P_0)

تقييم السلاسل الفردية (حساب BIC) في P_0

طالما $(t < G_{max})$ نفذ

اختيار من P_t عدد السلاسل الفردية من أجل التكاثر

توليد نسل بتطبيق معاملات وراثية

تقييم النسل (حساب BIC)

اختيار النسل لإدخاله إلى المجتمع التالي $(P + 1)$

اختيار الباقي من P_t ليُعاد إدخاله إلى $(P + 1)$

زيادة الزمن الحالي $(t: = t + 1)$

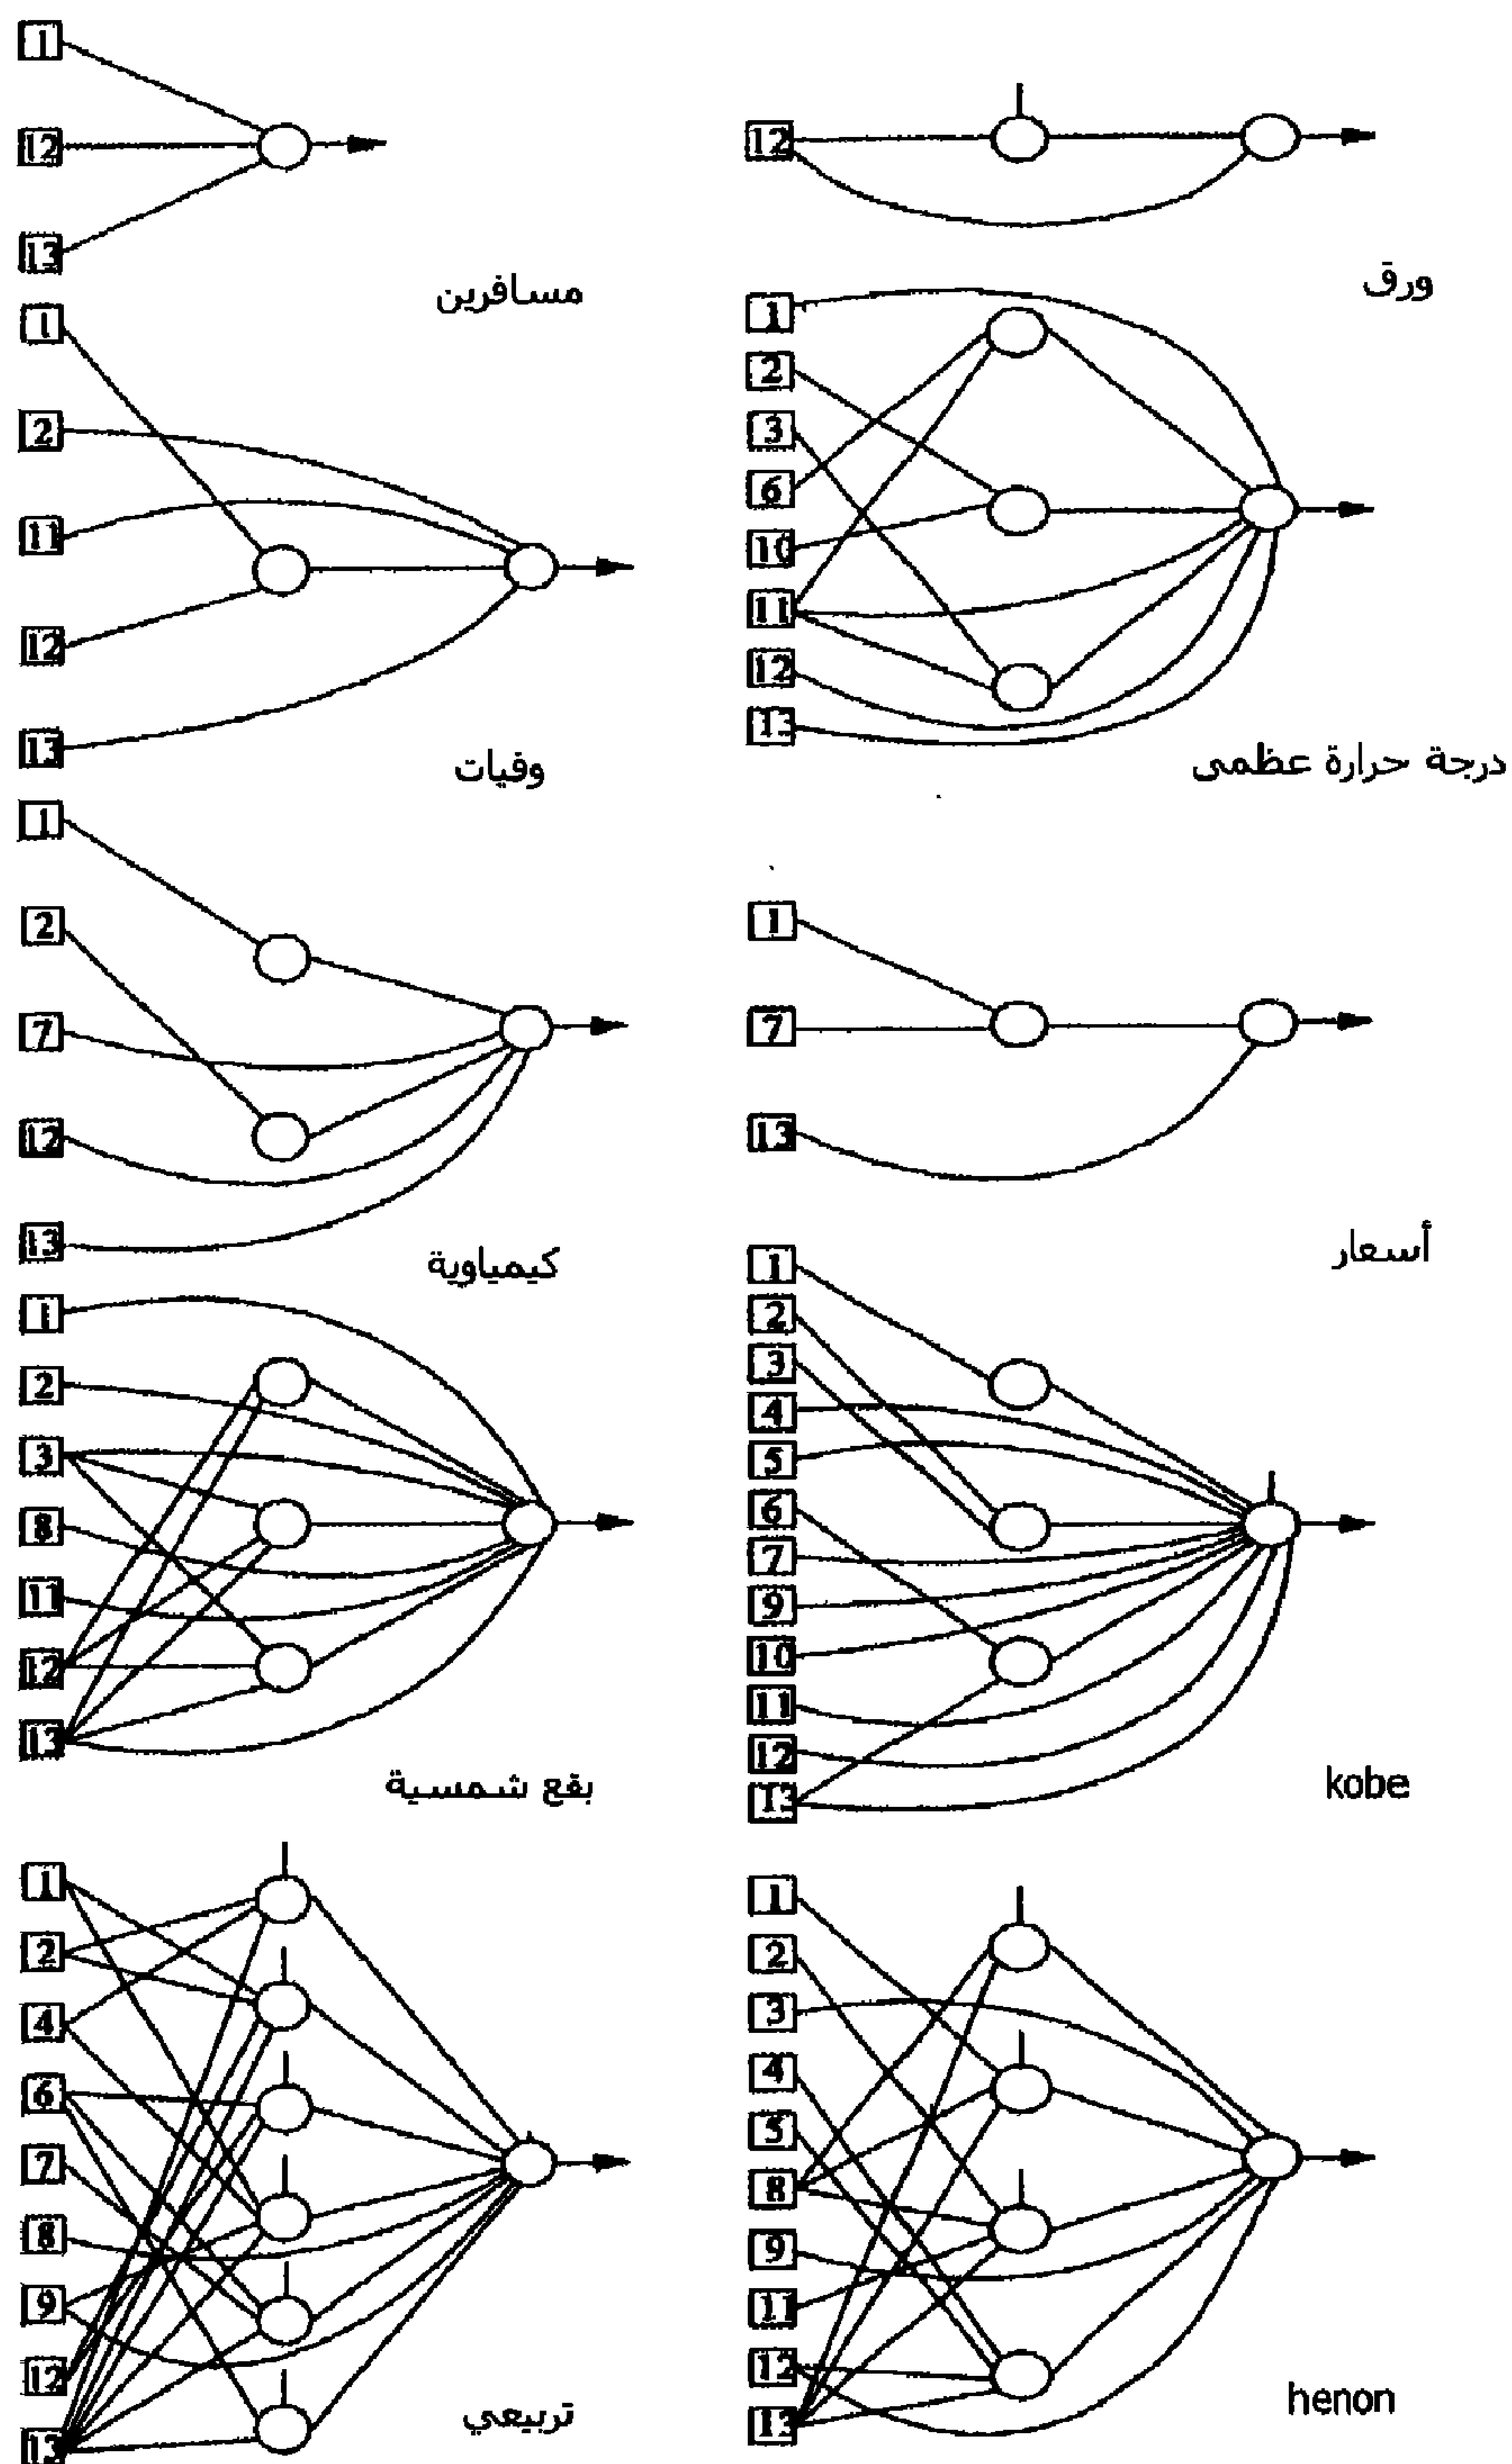
نهاية

يعرض (الجدول 4) و(الشكل 6) النماذج الأفضل المنجزة بالطريقة الوراثية العصبونية.

يرمز العمود R إلى عامل التخفيض عند مقارنة عدد الأوزان للطبولوجية التي تم الحصول عليها (P) مع الطبولوجية الأساسية المكافئة المتصلة كلياً (P_{fc}):

$$R = 1\frac{P}{P_{fc}} \qquad (7)$$

الشكل (6) *أفضل طبولوجيات التنبؤ العصبونية المتطورة*



الجدول (4) أفضل نماذج التنبؤ العصبونية المُعطاة بالطريقة التطويرية

السلسلة	النافذة الزمنية	عقدة خفية (H)	أوزان (P)	عامل تخفيض (R)	التنبؤ ($RMSE_f$)
مسافرون	<1, 12, 13>	0	3	% 97	0.3 ± 18.2
ورق	<12>	1	4	% 96	0.6 ± 52.6
وفيات	<1, 2, 11, 12, 13>	1	6	% 94	1 ± 132
درجة حرارة عظمى	<1, 2, 3, 6, 10, ..., 13>	3	13	% 88	0.01 ± 0.87
كيمياوية	<1, 2, 7, 12, 13>	2	7	% 93	0.01 ± 0.36
أسعار	<1, 7, 13>	1	4	% 96	0.01 ± 7.49
بقع شمسية	<1, 2, 3, 8, 11, 12, 13>	3	17	% 84	0.5 ± 17.4
kobe	<1, ..., 7, 9, ..., 13>	3	17	% 84	8 ± 498
تربيعي	<1, 2, 4, 6, 7, 8, 9, 12, 13>	6	34	% 67	0.00 ± 0.01
henon	<1, ..., 5, 8, 9, 11, 12, 13>	4	23	% 78	0.03 ± 0.24

تقع قيم R هي ضمن المجال من 67 إلى 97% مبدية تشذيباً كبيراً بالخوارزمية الوراثية. في الواقع، تستقبل كافة العقد الخفية عدداً قليلاً من الاتصالات (من 1 إلى 4). علاوة على ذلك، يبدو أن البنى الهندسية المختارة مضبوطة على تعقيد للسلسلة بما مجموعه من 3 إلى 13 وزن للسلاسل الخطية و17 وزن للسلاسل اللاخطية، وترتفع إلى 23 و34 اتصال للبيانات العشوائية. تقدم كافة الطبولوجيات المتطورة اتصالات مختصرة تشهد على فائدتها. على النقيض من ذلك، تبدو اتصالات الانحياز أقل أهمية. وكمثال، يرسم (الشكل 7) التنبؤات من أجل العناصر الـ 29 الأخيرة (10 %) من سلسلة البقع الشمسية. في هذه الحالة، يكون منحني القيم الحقيقية ومنحني التنبؤ قريبان من بعضهما البعض، وهذا ما يكشف ملاءمة جيدة للنموذج العصبوني.

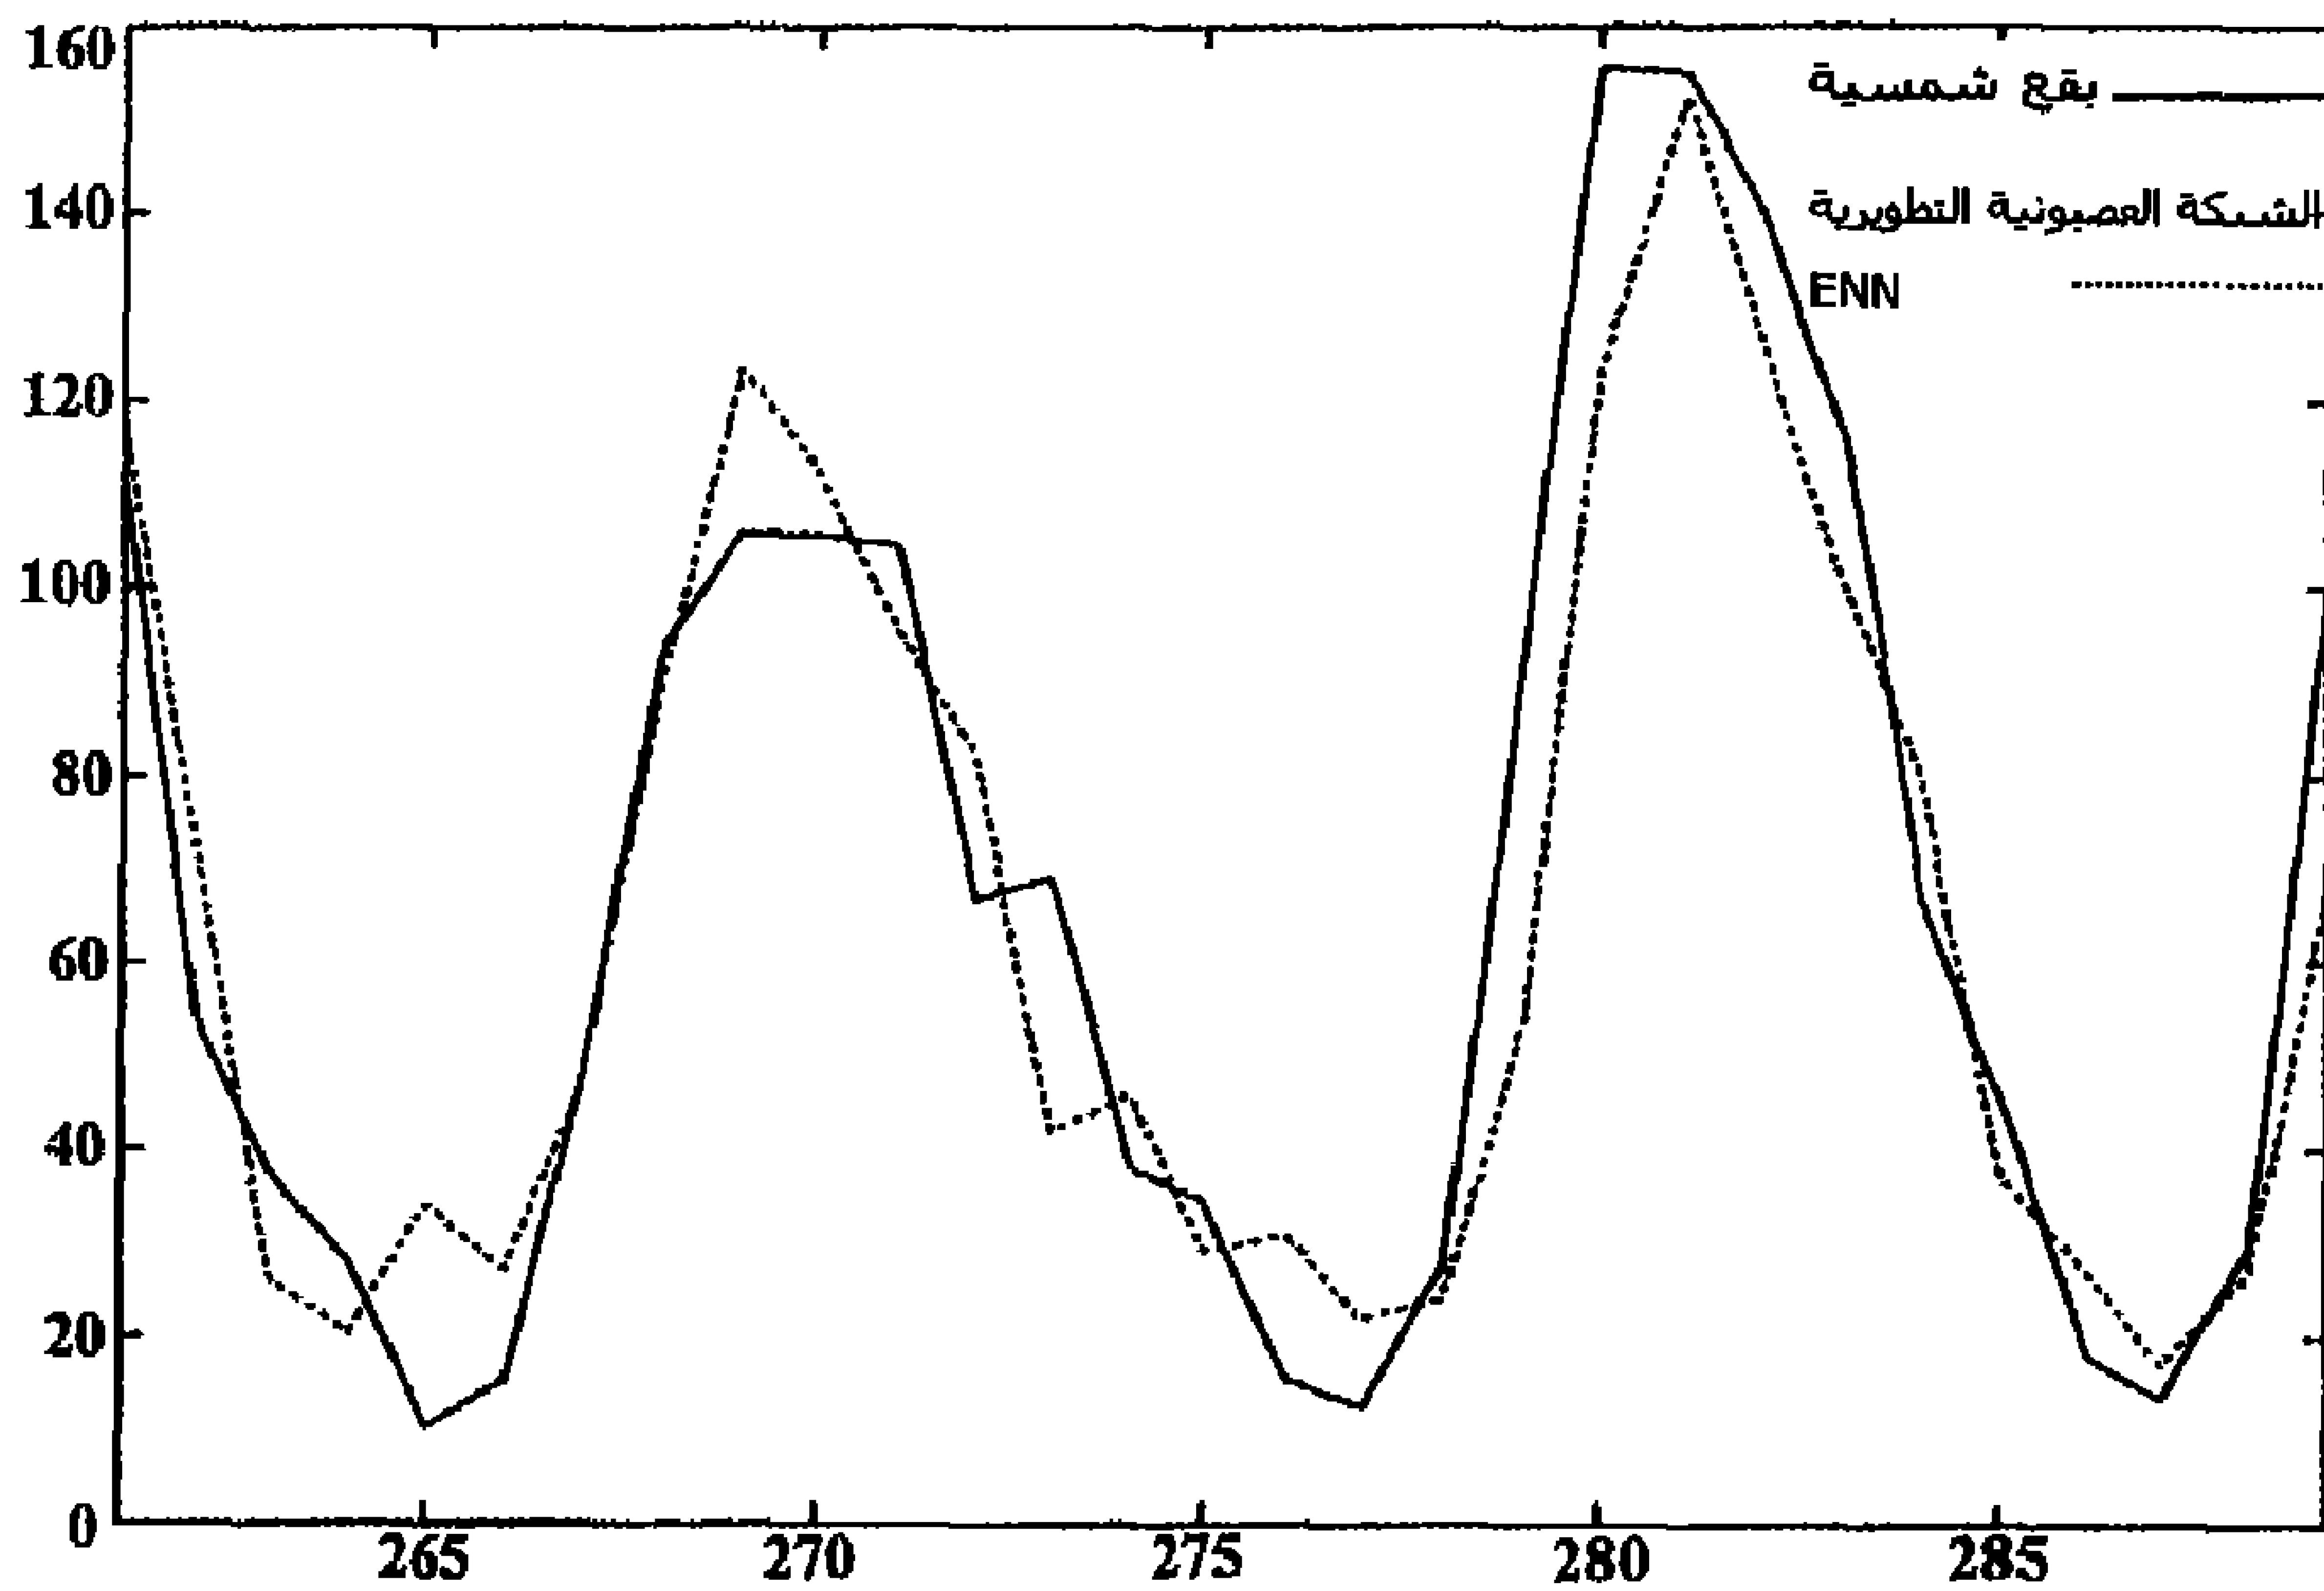
المناقشة

سيُبدأ هذا القسم بمقارنة بين طرق تنبؤ السلاسل الزمنية التقليدية والعصبونية. تمت أَمْثَلة بارامترات الـ Holt-Winters باستخدام 0.01 بحث شبكي من أجل خطأ التدريب الأفضل (RMSE) الذي يمثل تطبيقاً شائعاً في مجال التنبؤ (الجدول 5).

اُتخذت استراتيجية مختلفة من أجل المنهجية Box-Jenkins، بما أن مرحلة اختيار النموذج هي مرحلة غير عادية، وتتطلب استخدام خبراء. فقد قُرر استخدام رزمة التنبؤ (Ryeroft, 1993) Forecast PRO التي تحتوي على اختيار نموذج آلي (الجدول 6).

على الرغم من أن هناك نماذج معروفة في المراجع والدوريات العلمية (Box & Jenkins, 1976). فإن هذه النماذج لم تُؤخذ بالاعتبار، باعتبار أنها تغطي أربعة فقط من السلاسل المختبرة. علاوة على ذلك، فقد بدأت النماذج الموجودة في تلك المراجع والدوريات العلمية أخطاء تنبؤ أعلى.

الشكل (7) *القيم الحقيقية للبقع الشمسية والتنبؤات المُعطاة بالخوارزمية العصبونية التطويرية للعناصر الـ 29 الأخيرة.*



الجدول (5) نماذج الـ Holt-Winters للتنبؤ المكتسبة بـ 0.01 بحث شبكي.

السلسلة	α	β	γ	k	$RMSE_t$
مسافرون	0.29	0.03	0.95	12	16.5
ورق	0.25	0.01	0.03	12	49.2
وفيات	0.36	0.00	0.01	12	135
درجة حرارة عظمى	0.24	0.00	0.01	12	0.72
كيمياوية	0.30	0.00	-	-	0.35
أسعار	1.00	0.02	-	-	7.54
بقع شمسية	1.00	0.95	-	-	28.4
kobe	0.05	0.00	-	-	3199
تربيعي	0.03	0.00	-	-	0.35
henon	0.02	0.75	-	-	0.73

الجدول (6) نماذج التنبؤ المكتسبة بالمنهجية Box-Jenkins

السلسلة	μ	A_i^*	M_i^*	RMSEf
مسافرون†	0.0	$<I_1, I_{12}, -I_{13}>$	$<-0.35_1, -0.62_{12}, 0.22_{13}>$	17.8
ورق†	0.0	$<I_1, I_{12}, -I_{13}>$	$<-0.87_1, -0.80_{12}, 0.70_{13}>$	61.0
وفيات†	0.0	$<I_1, I_{12}, -I_{13}>$	$<-0.66_1, -0.90_{12}, 0.59_{13}>$	144
درجة حرارة عظمى†	0.0	$<I_1, I_{12}, -I_{13}>$	$<-0.88_1, -0.89_{12}, 0.78_{13}>$	0.91
كيمياوية	0.3	$<0.90_1>$	$<-0.56_1>$	0.35
أسعار	0.0	$<I_1>$	$<0.12_1>$	7.72
بقع شمسية	14.2	$<1.39_1, -0.70_2>$	< >	28.4
kobe	3038	$<0.71_1, -0.81_2>>$	$<0.77_1, -0.21_2, -0.06_3>$	582
تربيعي	0.48	< >	< >	0.35
henon	0.25	< >	$<-0.30_1, 0.14_2, -0.40_3>$	0.63

* - ترمز القيم إلى معاملات (M_i و A_i) وتشير الرموز الدليلية إلى التأخيرات الزمنية (j, i).

† أستخدمت نماذج SARIMA للسلاسل الموسمية.

< > نُفذت المعالجة الأولية للبيانات بتحويل لوغاريتمي طبيعي.

في (الجدول 7)، تمت مقارنة أداء الطريقة المقترحة بتقنيات التنبؤ التقليدية: التقنية Holt-Winters (HW) والتقنية Box-Jenkins (BJ). قيم الخطأ في الجدول مُعطاة بالإحصائية U للعالم Theil المُعرّفة بالعلاقة التالية:

$$Theil's\,U = \frac{RMSE_f}{RMSE_n} \qquad (8)$$

حيث تمثل $RMSE_n$ خطأ التنبؤ المعطى بتوقع عدم تغيير بسيط ($\hat{X}_t = X_{t-1}$). يأخذ هذا القياس قيماً ضمن المجال 0 (تنبؤ تام) إلى حوالي الواحد، منفذاً مقارنة بين السلاسل المختلفة بطرق أسهل. يرمز العمود BNN إلى النتائج المكتسبة بالنموذج العصبوني ذي الأساس المتعلم، أي شبكة متصلة كلياً بـــ 13 مدخل و6 عقد خفية.

يظهر تحليل (الجدول 7) بأن البنية الهندسية ذات الأساس المتعلم تؤمن أسوأ أداء عصبوني، الذي ربما ينـــتج عن الإفراط في الأوزان ويؤدي إلى خسارة التعميم. يظهر ذلك، بأنه من الضروري أن تتابع استراتيجيات اختيار نموذج أكثر حنكةً وتطوراً. في الحقيقة، عند مقارنة الطرق الربطية، فإن أفضل النتائج المكتسبة كانت بالشبكة العصبونية التطويرية (باستثناء سلسلة الورق Paper التي تصادق على استخدام الخوارزمية الوراثية.

الجدول (7) المقارنة (قيم Theil'sU) بين طرق التنبؤ التقليدية ((Box-Jenkins(BJ), Holt-Winters (HW)) وطرق التنبؤ العصبونية (شبكة عصبونية ذات أساس متعلم (BNN)، اختيار نموذج تجريبي (HMS)، وشبكة عصبونية تطويرية.

السلسلة	HW	BJ	BNN	HMS	ENN
مسافرون	0.104	0.118	0.137	0.125	0.123
ورق	0.035	0.076	0.079	0.055	0.057
وفيات	0.501	0.496	0.459	0.429	0.420
درجة حرارة عظمى	0.137	0.186	0.138	0.131	0.125
كيماوية	0.830	0.861	0.881	1.060	0.873
أسعار	1.000	1.008	1.899	0.997	0.997
بقع شمسية	0.762	0.434	0.401	0.301	0.287
kobe	0.823	0.027	0.031	0.025	0.020
تربيعي	0.464	0.464	0.136	0.024	0.000
henon	0.417	0.326	0.174	0.110	0.053

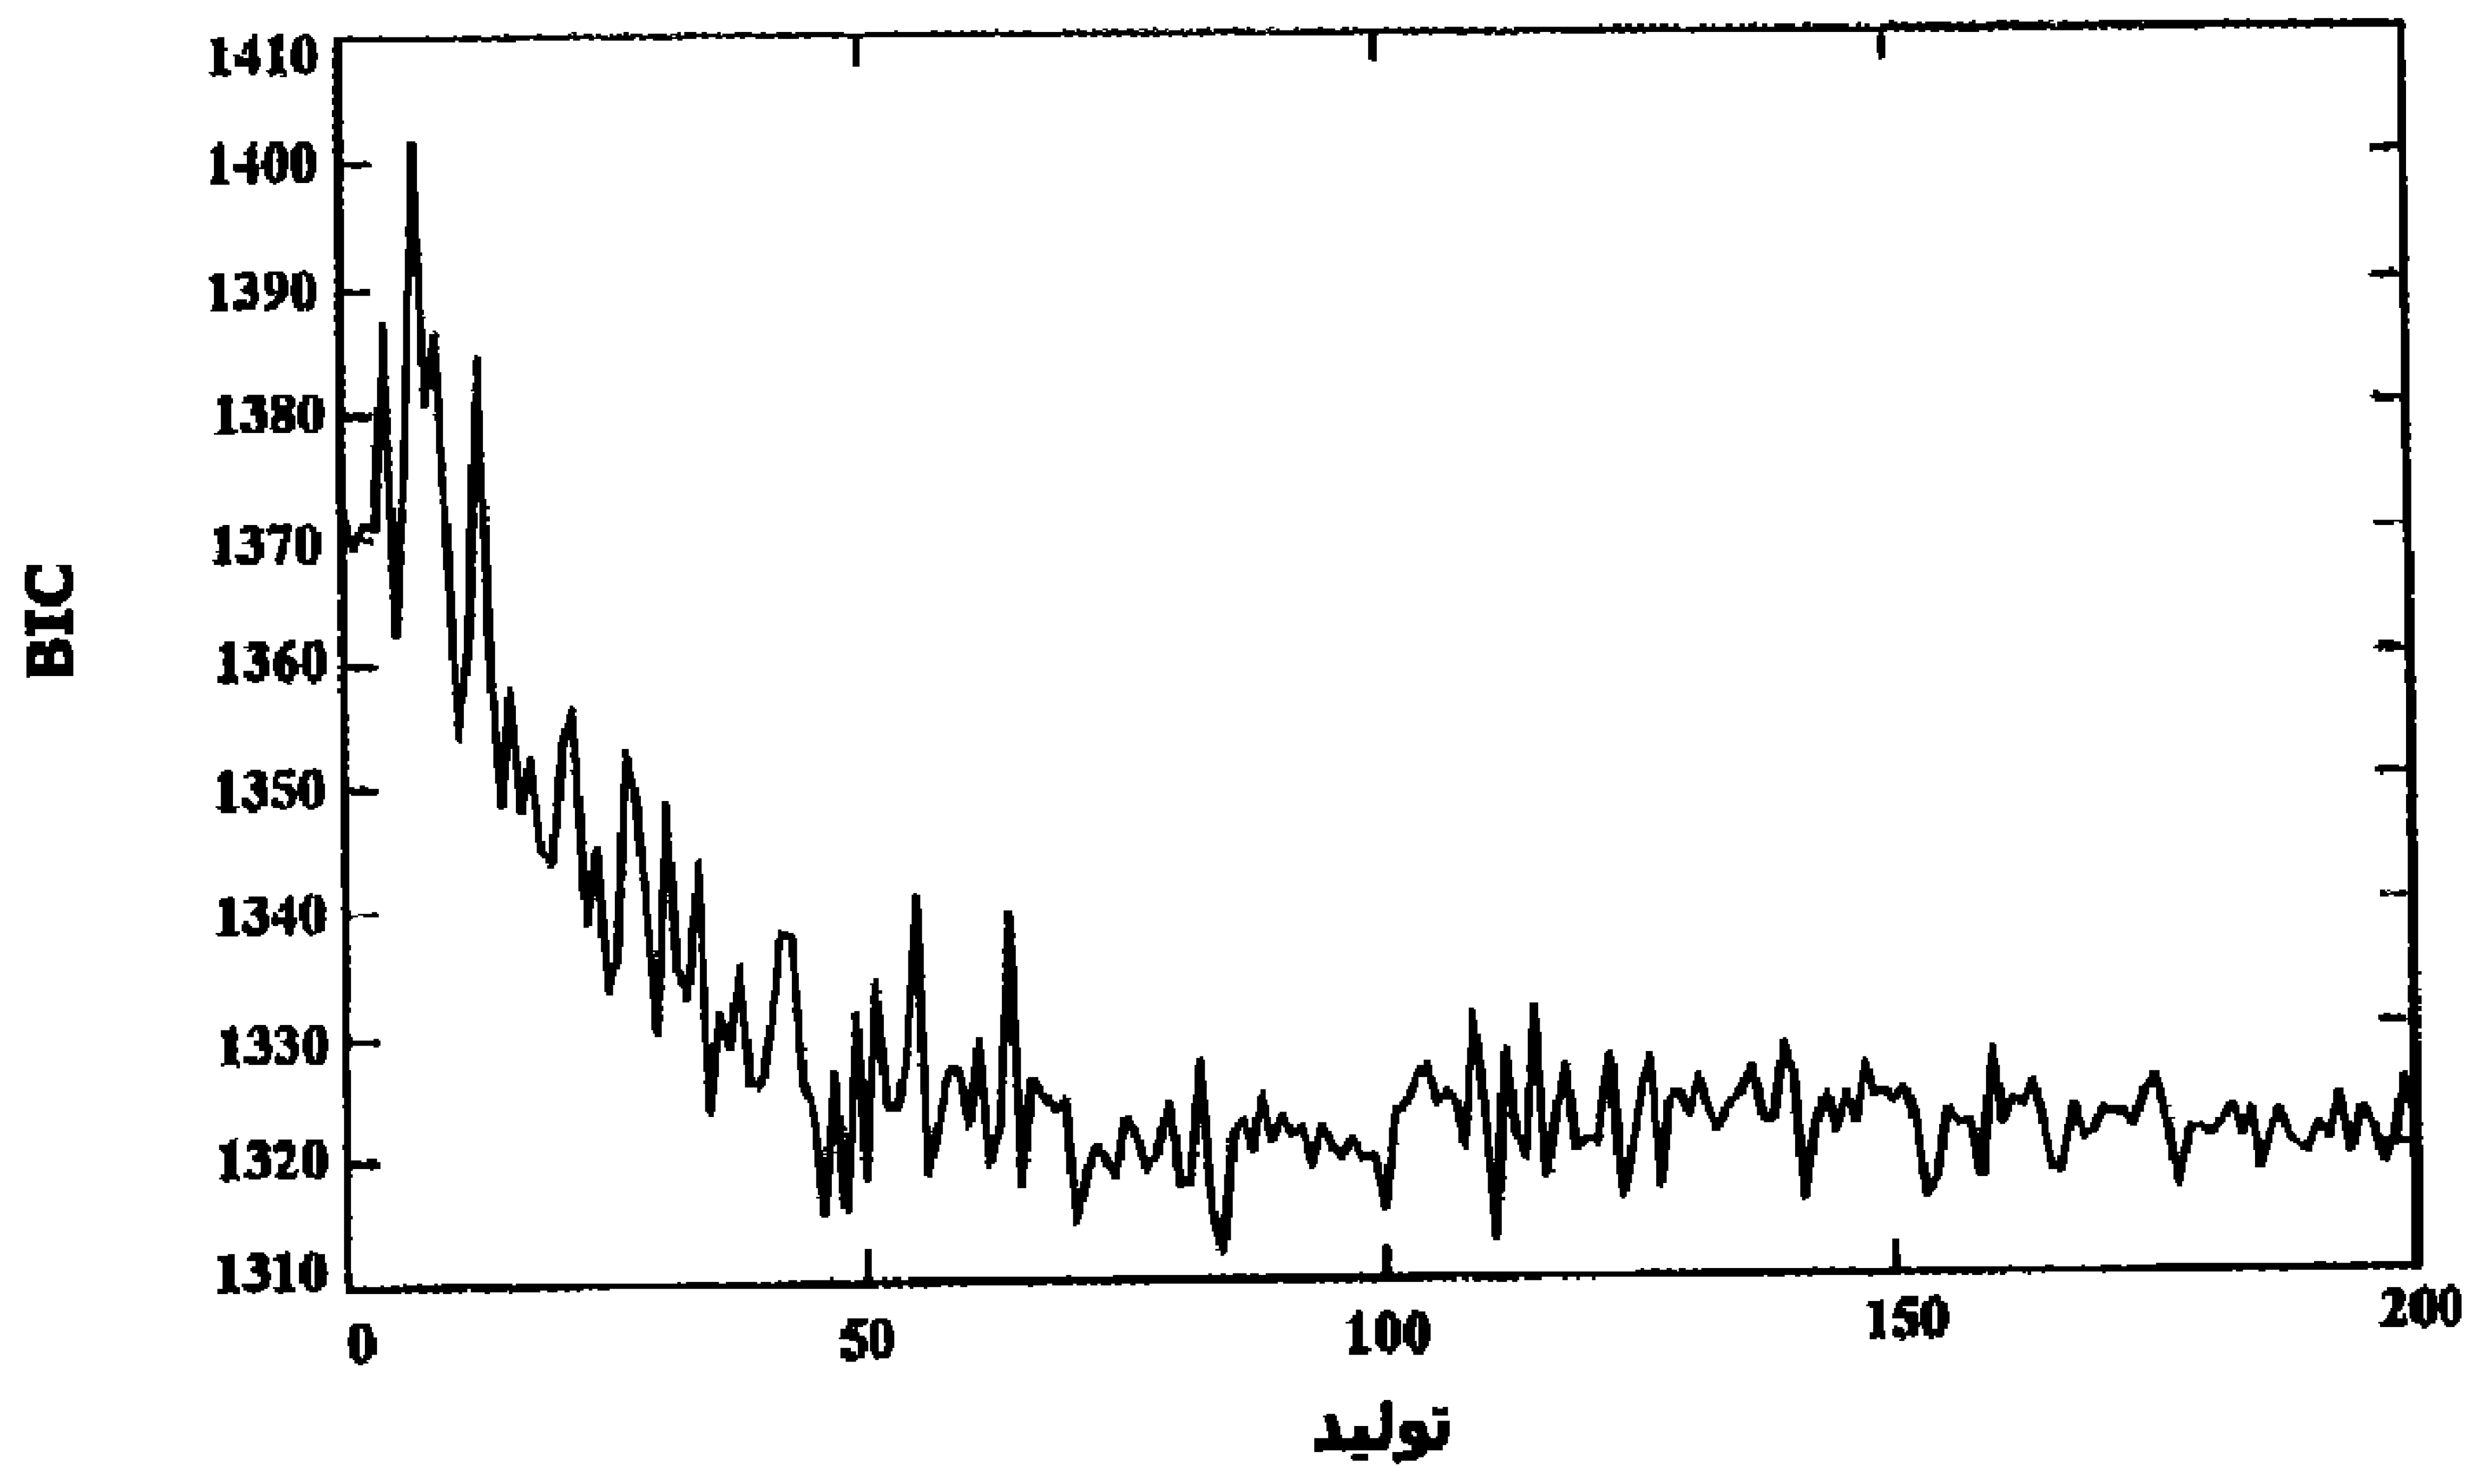
تُظهر المقارنة مع الطرق التقليدية، بأن طريقة العالمين Holt-Winters تعطي أداء أفضل للسلاسل الموجهة الموسمية. وهذا الأمر غير مفاجئ طالما أنها طُوّرت خصيصاً من أجل هذا النوع من البيانات. في السلاسل الموجهة، تعاني كافة التقنيات من صعوبة في تحقيق أداء أفضل من التنبؤ بدون تغير، ومن كلا التقنيتين: تقنية Holt-Winters وتقنية الشبكة العصبونية التطويرية اللتان تعطيان نتائج مشابهة. يختلف هذا السيناريو عند اعتبار سلاسل أخرى، حيث تعرض الخوارزمية الوراثية قوتها بتنفيذ أداء أفضل من كلا طريقتي التنبؤ التقليديتين، وبخاصةً من أجل السلاسل الأربعة الأخيرة.

تتفوق المنهجية Box-Jenkins على الطريقة Holt-Winters في أربعة سلاسل (الوفيات، البقع الشمسية، kobe، henon)، وتتفوق في الأداء على الاستراتيجية العصبونية التطويرية فقط في مجموعتي بيانات (المسافرين، والكيماوية).

العائق الرئيس للطريقة المقترحة لاختيار النموذج هو الزيادة في المجهود الحسابي. تتطلب الأَمْثَلة التطويرية عمليات حسابية أكثر بخمس مرات من استراتيجية اختيار النموذج التجريبي، وبالتالي، إذا لم يكن هناك حاجة ملحة للدقة، فإن استعمال طريقة تجريبية أبسط يمكن أن يؤمن حلولاً مقبولة. على الرغم من هذا، يمكن تقليل التعقيد الزمني إذا وضعت مجموعة جزئية من النماذج المرجوة في المجتمع الابتدائي للخوارزمية الوراثية، مع أن ذلك قد يتطلب استخدام معلومات سابقة. بما أن معظم السلاسل الزمنية تستخدم بيانات يومية أو شهرية، فإن ذلك لا

يعتبر مشكلة رئيسية. وكمثال على مجهود المعالجة، يرسم (الشكل 8) الملاءمة الأفضل (BIC) المكتسبة في كل توليد لسلسلة البقع الشمسية. في هذه الحالة، يُرصد تقارب أعلى في التكرارات الأولى بكونها الحل الأفضل المكتسب في توليد رقم 86. يُظهر هذا السلوك – الذي حدث في كافة السلاسل – بأن الحلول المقبولة يمكن الحصول عليها في مراحل أبكر من العملية.

الشكل (8) *قيمة الملاءمة (BIC) الأفضل المكتسبة أثناء التوليد بالخوارزمية الوراثية من أجل سلسلة البقع الشمسية.*



تتعلق قضية التنبؤ الأخرى بمعرفة توضيحية أو تفسيرية، ففي تطبيقات التنقيب عن البيانات، يكون من المهم أيضاً التزود بمعرفة مفيدة حول ماهية تعلّم النموذج إلى جانب الحصول على دقة تنبؤ جيدة (Fayyad, Piatetsky-Shapiro, & Smyth, 1996). على أية حال، من الصعب على البشر فهم كيف توضح شبكات Perceptrons متعددة الطبقات متصلة كلياً سلوك سلسلة معطية. موجهةً بمعيار BIC، تنجز الطريقة التطويرية تشذيب كبير الذي يؤدي إلى نماذج أبسط قابلة للفهم أكثر. على سبيل المثال، من الطبولوجية العصبونية للبقع الشمسية على (الشكل 6)، يمكن استنتاج وجود تأثير خطي بخصوص التأخيرات الزمنية 1، 2، 8 و11 وتأثير لا خطي معدل من الآخرين (3، 12، 13).

تبين الملاحظة الأخيرة على مجموعات البيانات المستخدمة كنقاط علام، أنه على الرغم من كونها ذات حجم صغير (الجدول 1)، فإنها تمثل الأطوال العامة الموجودة في سلاسل زمنية شهرية أو سنوية) للعالم الحقيقي. في الحقيقة، أن أغلبية الـ 800 سلسلة المتوفرة في مستودع مكتبة بيانات السلاسل الزمنية تحتوي فقط على بضعة مئات من البيانات (Hyndman & Akram, 2005). على

أية حال، توجد أيضاً مجالات أخرى في العالم الحقيقي تتطلب التعامل مع مجموعات بيانات ضخمة وخصوصاً في وجود تنبؤ الزمن الحقيقي. كأمثلة على مثل هذه التطبيقات، نذكر: معدل نبضات قلب مرضى العناية المشددة (Weigend & Gershenfeld, 1994)، أو حركة العمل على الانترنت (Basu & Mukherjee, 1999). تم في الدراسة السابقة إظهار (Cortez, Allegro, Rocha, & Neves, 2002).

أنه يمكن نمذجة حتى السلاسل الكبيرة بشبكات عصبونية صغيرة. لهذا، لا تطرح الطريقة التطويرية المقترحة مشاكل موجهة، على الرغم من أن التعقيد الحسابي سيكون قضية رئيسية إذا ما تطلب الأمر تنبؤاً بزمن حقيقي (بالثواني مثلا).

الاتجاهات المستقبلية

كان هناك في العقود القليلة الأخيرة جهود متزايدة لتحسين عملية اتخاذ القرارات. في الحقيقية، لقد ساهمت ثلاثة عوامل رئيسية لتأكيد أقوى في استعمال طرق التنبؤ:

- نمو صناعة أنصاف النواقل، الذي أدى إلى قدرة حسابية عالية بتكلفة منخفضة.
- الزيادة الأسية في تخزين البيانات وأجهزة الاكتساب الآلية.
- تطوير أدوات كشف آلية جديدة.

على الرغم من المساعدات اللاخطية المزودة من قبل الشبكات العصبونية الصنعية، فإن أغلبية المنظمات ما تزال تستخدم فقط طرق التنبؤ التقليدية (Makridakis et at., 1998). على الرغم من أن هذا السيناريو يتوقع له التغيير عندما يصبح المحللون والمدراء أكثر ألفةً ومعرفة بالنماذج الربطية. في الوقت الحاضر، تكمن العقبات الرئيسية للتنبؤ بالشبكات العصبونية المتجادل عليها في نقص الفهم والإدراك الناتج عن نمذجة الصندوق الأسود (أي المغلقة) وتعقيدات الاستخدام عند مقارنتها بطرق أخرى. رغم ذلك، ستزال هذه الادعاءات عندما يستمر البحث في المعرفة التفسيرية كاستخلاص قواعد الشبكات المدربة (Setiono, 2003) ومنهجيات اختيار النموذج كالمنهجية المقدمة في هذا الفصل.

بالنسبة للبنى الهندسية للشبكات العصبونية، ما تزال شبكات Perceptrons متعددة الطبقات خياراً شعبياً (شائعاً)، طالما أنها متوفرة في عدة وزم جاهزة. على الرغم من ذلك، يتوقع أن تأخذ أنواع أخرى من الشبكات أهمية كالتوابع الأساسية الشعاعية والشبكات التكرارية. وحديثاً جداً، بدأ اهتمام متزايد في استخدام آليات الدعم الموجهة Support Vector machines، التي هي تقنيات لاخطية تقدم أفضليات نظرية (مثل غياب الحدود الدنيا المحلية) على شبكات عصبونية.

على سبيل المثال، قام العالمان Gao وTay (2003) بتطبيق آليات الدعم الموجهة على سلاسل مالية، وتم الحصول على نتائج منافسة بمقارنتها مع شبكات الانتشار الخلفي.

تعتمد طريقة أخرى غير تقليدية ممكنة على استخدام الحوسبة التطويرية، التي يتوقع لها زيادة في الاهتمام مدفوعةً بميزاتها مثل التمثيل النموذجي الواضح والبحث العام التكيفي. حالياً، يوجد أسلوبان واعدان: الأول، أَمْثَلَة طرق التنبؤ التقليدية - كنموذج ARMA (المعادلة 4) - بخوارزميات تطويرية معتمدة على تمثيلات لقيم حقيقية (Cortez, Rocha & Neves, 2004)، والثاني، استخدام البرمجة الوراثية ببناء تعبير عددي مؤلف من مجموعة من التأخيرات الزمنية والمعاملات كتلك المأخوذة من الأبجدية {'+'، '-'، '*'، '/'} (Kaboudan, 2003).

قدم هذا الفصل طريقة ترميز مباشرة لتصميم شبكة عصبونية، وقد وضعت أوزان الاتصالات بالخوارزمية RPROP. رغم ذلك، فهذه الإجراءات المعتمدة على التدرج ليست معفية من الوقوع في فخ الحدود الدنيا المحلية (Rocha, Cortez, & Never, 2003). إحدى الإمكانيات لتخفيف هذه المشكلة ستكون بالتطور الآني للبنية الهندسية ولأوزان الاتصالات (Yao, 1999). إن الخوارزمية الوراثية جذابة من أجل تدريب الأوزان، لأنها تنفذ بحثاً عاماً وشاملاً متعدد النقاط. علاوة على ذلك، فإنه من الممكن دمج كلا البحث التدريجي والتطوري من أجل التدريب العصبوني باستخدام أَمْثَلَة لامارسك (Rocha et at., 2003).

هل سيكون من الممكن مستقبلاً تحقيق طريقة عامة لتنبؤ أي نوع من السلاسل الزمنية؟ إن الجواب كما أُشير من قبل العالمين Weigend وGershenfeld (1994) سلبي وهو متعلق بنظرة هيلبرت لتحويل كافة الرياضيات إلى مجموعة من البديهيات واضحة المعالم. وهو الحلم الذي أُنهي بنظرية العالم جوديل Gödel. كبديل لذلك، يقترح العالمان Gershenfeld وWeigend هدفاً أكثر واقعية لإيجاد النموذج الأفضل لسلسلة مُعْطاة، حيث تعني كلمة أفضل النموذج الذي يتطلب معلومات أقل لشرح ظاهرة معطية بشكل صحيح. يعقد الأمل على مساهمة التطورات المستقبلية في الأنظمة اللاخطية وعلوم الحاسوب والشبكات العصبونية الصنعية في حل هذه الموضوع.

الاستنتاجات

لقد خلقت الموجة العارمة للتقنيات الربطية - مثل شبكات Perceptrons متعددة الطبقات - إمكانيات جديدة في مجال التنبؤ. حالياً، يتطلب تطبيق تلك النماذج بعض الجهد من قبل أي محلل في تنفيذ عمليات كتحليل البيانات واختيار النموذج. تُقّدم في هذا الفصل طريقة تكيفية لا

تفترض وجود معرفة مسبقة لكل سلسلة. علاوة على ذلك، تعمل المنظومة المقترحة بشكل آلي منفذةً اختيار النموذج بسرعة فائقة، وتكون قادرة على الاختيار بين شبكات متعددة الطبقات مختلفة ممتدةً من نماذج خطية إلى أخرى لا خطية معقدة. على أية حال، هذه الاستقلالية المضافة لها عائق متمثل في زيادة التعقيد الحسابي.

طُبقت تجارب للمقارنة بين الطرق التقليدية (على سبيل المثال Holt-Winters وBox-Jenkins) بعدة سلاسل حقيقية واصطناعية من محاولات مختلفة.وقد أظهرت تلك التجارب بأن طريقة الـــ Holt-Winters – على الرغم من أنها بسيطة جداً – تقدم أداءً جيداً مع السلاسل الخطية ذات المكونات الموجهة والموسمية. على أية حال، عندما يصبح المجال أكثر تعقيداً – بسلوك لا خطي – تصبح الطريقة التقليدية غير مناسبة بشكل واضح. تظهر الطريقة العصبونية المقترحة قوتها تماماً في هذه السيناريوهات.

من جهة أخرى، كان من الممكن تأكيد واثبات أن الشبكات العصبونية – كشبكات Perceptrons متعددة الطبقات – هي بالفعل أدوات فعالة جداً لمهام التراجع، أنها تعتمد بشدة على التصميم الشبكي. تزود البنى الهندسية الضعيفة بإمكانيات تعلم غير كفوءة، في حين تؤدي الشبكات المعقدة جداً إلى مبالغة في الإحكام. تكمن إمكانية واعدة لاختيار الطبولوجيا في استخدام توليفة هجينة من الإجراءات العصبونية والتطويرية. في الحقيقة، تثبت الخوارزمية الوراثية - المأخوذة هنا كمحرك رئيس – بأنها أداة اختيار نموذج قوي وفعال. بالنسبة إلى تقييم إمكانيات تعميم التنبؤ العصبوني، فإن إحصائية BIC – التي تعيق التقيد – قدمت نفسها كحل مناسب وكاف. كما قدم هذا المعيار أيضاً ميزة تطلب حسابات بسيط، بينما يزيد ضغط الاختيار لجهة بنًى هندسية أبسط تكون أكثر فهماً.

من المرتقب في المستقبل تطبيق شبكات عصبونية تطويرية على أنواع تنبؤ أخرى – مثل التنبؤ بعيد المدى أو متعدد الأشكال أو التنبؤ بالزمن الحقيقي – في تطبيقات العالم الحقيقي (على سبيل المثال الهندسة البيولوجية (الحيوية) وحركة العمل على الانترنت). على الرغم من أن المنهجية المقترحة قد حصلت على نتائج مثيرة للاهتمام في ميدان تنافس التنبؤات، فإنها مفيدة بشكل فعال في المجالات الأخرى حيث يمكن تطبيق شبكات Perceptrons متعددة الطبقات (مهام التصنيف مثلاً). أخيراً، يُسعى لاستكشاف الأَمْثَلة التطويرية مع بنى هندسية عصبونية مختلفة (على سبيل المثال، شبكات عصبونية تكرارية).

المراجع

Basu, S., & Mukherjee, A. (1999). Time series models for Internet traffic. Proceedings of the 24th Conf. on Local Computer Networks (pp. 164-171).

Box, G., & Jenkins, G. (1976). Time series analysis: Forecasting and control. San Francisco: Holden Day.

Cao,L., & Tay, F. (2003). Support vector machine with adaptive parameters in financial time series forecasting. IEEE Transactions on Neural Networks, 14(6), 1506-1518.

Chatfield, C. (1993). Neural networks: Forecasting breakthrough or passing fad? International Journal ofForecasting, 9, 1-3.

Chen, S., & Lu, C. (1999). Would evolutionary computation help in designs ofANNs in forecasting foreign exchange rates? Proceedings of the 1999 Congress on Evolu- tionary Computation (vol. 1, pp. 267-274).

Cortez, P., Allegro, F., Rocha, M., & Neves, J. (2002). Real-time forecasting by bio-inspired models. In M. Hamza (Ed.), Proceedings of the 2nd International Conference on Artificial Intelligence and Applications (AIA),Málega, Spain (pp. 52-57).

Cortez, P., Rocha, M., Machado, J., .& Neves, J. (1995). A neural network based forecasting system. Proceedings of the ICNN'95 - IEEE Int. Conf. on Neural Networks, Perth, Western Australia (vol. 5, pp. 2689-2693).

Cortez, P., Rocha, M., & Neves, J. (2004). Evolving time series forecasting ARMA models. Journal of Heuristics10(4), 415-429.

Falco, I., Cioppa, A., Iazzetta. A., Natale, P., & Tar, E. (1998). Optimizing neural networks for time series prediction. Proceedings of the Third World Conference on Soft Computing (WSC3).

Faraday, J., & Chatfield, C. (1998). Times series forecasting with neural networks: A case study. Applied Statistics, 47, 231-250.

Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). The KDD process for extracting useful knowledge from volumes of data. Communications of ACM, 39(11), 27-34.

Flexer, A. (1996). Statistical evaluation of neural networks experiments: Minimum requirements and current practice. Proceedings of the 13th European Meeting on Cybernetics and Systems Research, Vienna, Austria (vol. 2, pp. 1005-1008).

Grau, F. (1992). Genetic synthesis of boolean neural networks with a cell rewriting developmental process. In D. Whitley & J. Schaffer (Eds.), Proceedings of COGANN, Los Alamitos, CA (pp. 55-74). IEEE.

Hanke, J., & Reitsch, A. (1989). Business forecasting. MA: Allyn and Bancon.

Harvey, A. (1989). Forecasting, structural time series models and the Kalman filter. Cambridge: C.U. P.

Haykin, S. (1999). Neural networks: A comprehensive foundation. Prentice-Hall.

Holland, J. (1975). Adaptation in natural and artificial systems. Unpublished doctoral thesis. University of Michigan, Ann Arbor.

Huang, W., Xu, B., & Chan-Hilton, A. (2004). Forecasting flows in Apalachicola River using neural networks. Hydrological Processes, 18, 2545-2564.

Hyndman, R., & Akram, M. (2005). Time series data library. Retrieved from www-personal.buseco.monash.edu.au/~hyndman/TSDL/

Kaboudan, M. (2003). Forecasting with computer-evolved model specifications: A genetic programming application. Computers & Operations Research, 30, 1661-1681.

Kwok, T., & Yeung, D. (1999). Constructive algorithms for structure learning in feedforward neural networks for regression problems: A survey. IEEE Transactions on Neural Networks, 8(3), 630-645.

Lapedes, A., & Farber, R. (1987). Non-linear signal processing using neural networks: Prediction and system modelling. Tech. Rep. LA-UR-87-2662, Los Alamos National Laboratory.

Makridakis, S., Wheelwright, S., & Hyndman, R. (1998). Forecasting: Methods and applications (3rd ed.). John Wiley & Sons.

Michalewicz, Z. (1996). Genetic algorithms + data structures = evolution programs (3rd ed.). Springer-Verlag.

Neves, J., Rocha, M., Rodrigues, H., Biscaia, M., & Alves, J. (1999). Adaptive strategies and the design of evolutionary applications, In W. Banzhaf et al. (Eds.), Proceedings of the Genetic and Evolutionary Computation Conference, Orlando, FL (pp. 473-479). Morgan Kaufmann.

Opitz, D., & Shavlik, J. (1994). Using genetic search to refine knowledge-based neural networks. In W. Cohen & H. Hirsh (Eds.), Proceedings of the 11th International Conference on Machine Learning. San Francisco: Morgan Kaufmann.

Peitgen, H., Jürgens, H., & Saupe, D. (1992). Chaos and fractals: New frontiers of science. New York: Springer-Verlag.

Riedmiller, M. (1994). Supervised learning in multilayer perceptrons: From backpropagation to adaptive learning techniques. Computer Standards and Interfaces, 16.

Rocha, M., Cortez, P., & Neves, J. (2003). Evolutionary neural network learning. In F Pires & S. Abreu (Eds.), Progress in artificial intelligence, LNA1 2902 (pp. 24-28). Springer.

Rycroft, R. (1993). Microcomputer software of interest to forecasters in comparative review. International Journal of Forecasting, 531-575.

Sarle, W. (1995). Stopped training and other remedies for overfitting. Proceedings of the 27th Symposium on the Interface of Computer Science and Statistics (pp. 352-360).

Schwarz,G. (1978). Estimating the dimension of a model. The Annals of Statistics, 6, 461-464.

Setiono, R. (2003). Techniques for extracting classification and regression rules from artificial neural networks. In D. Fogel & C. Robinson (Eds.), Computational intelligence The experts speak (pp. 99-114). IEEE Press/Wiley Interscience.

Shoneburg, E. (1990). Price prediction using neural networks: A project report. Neurocomputing, 2, 17-27.

Siddiqi,A., & Lucas,S. (1998). A comparison of matrix rewriting versus direct encoding for evolving neural networks. Proceedings of the IEEE Int. Conf. on Evolutionary Computation (pp. 392-397). Piscataway, NJ: IEEE Press.

Tang, Z., & Fishwick, F. (1993). Feed-forward neural nets as models for time series forecasting. ORSA Journal of Computing, 5(4), 374-386.

Thimm, G., & Fiesler, E. (1995). Evaluating pruning methods. Proceedings of the International Symposium on Artificial Neural Networks, Taiwan, Republic of China (pp. 20-25).

Tong, H. (1983). Threshold models in non-linear time series analysis. Springer lecture notes in statistics 21. Springer-Verlag.

Ulbricht, C. (1994). Multi-recurrent networks for traffic forecasting. Proceedings of AAAI'94 Conference, Seattle, WA.

Weigend, A., & Gershenfeld, N. (1994). Time series prediction: Forecasting the future and understanding the past (pp. 3'" ed.). Addison-Wesley.

Winters, P. (1960). Forecasting sales by exponentially weighted moving averages. Management Science, 6, 324-342.

Yao, X. (1999). Evolving artificial neural networks. Proceedings of the IEEE, 87(9), 423-1447.

الفصل الرابع

تطوير الشبكات العصبونية الصنعية بالاتصالات التكيفية بواسطة الحوسبة التطويرية

ملخص

يقدم هذا الفصل استخدام الشبكات العصبونية الصنعية Artificial Neural Networks (ANN) وتقنيات الحوسبة التطويرية Evolutionary Computation (EC) لحل مسائل العالم الحقيقي متضمنةً تلك المسائل ذات المركب الزمني. يبقي تطوير ANN بعض المشاكل من بداية حقل ANN التي يمكن أن تُبرر بتطبيق EC لتطوير ANN. نقترح في هذا الفصل منظومة متعددة المستويات معتمدةً على كل مستوي في EC لضبط البنية الهندسية وتدريب الـــ ANNs. أخيراً، تقدم المنظومة المقترحة إمكانية إضافة ميزات جديدة لعناصر المعالجة Processing elements (PE) ANN بدون تعديل عملية التطوير. تجعل هذه العملية من الممكن حدوث تقارب أسرع بين الشبكات العصبونية الطبيعية و ANN.

مقدمة

لقد تم إظهار بأنه لكي تكون الطبيعة طريقة فعالة لحل المشاكل، التي هي أشكال لا تحصى من الحياة وبالتالي فهناك حلول لا تعد لمشكلة البقاء، لأنها تصنع أسلوبها وطريقتها في العيش في الظروف المعقدة والأكثر شيوعاً.

تم إنجاز خطوات كبيرة في مجالات علمية متعددة عن طريق محاكاة آليات محددة للطبيعة، ويمكن أن تكون ANNs (Freeman & Skapura, 1993)، التي تعتمد على نشاط الدماغ مثالاً على ذلك، وقد استخدمت في تمييز الأنماط والأشكال وفي مهام التصنيف. المثال الآخر على هذا التكافل بين العلم والطبيعة هو EC (Holland, 1975, Bäck, 1996) التي تعتمد تقنياها على التطور بوساطة الاصطفاء الطبيعي وبخصوص مجتمع الحلول الكامنة لمشكلة ما معطاة، حيث تُطبق كلا عمليتي التصالب والطفرة. تستخدم EC بشكل رئيسي في وظائف الأمْثَلة والملاءمة.

ANNs هي حالياً الأفضل والأنسب بين تقنيات الذكاء الصنعي لتمييز الأنماط والأشكال. وعلى الرغم من أن هذه التقنية ليست خالية كلياً من المشاكل، فإنه خلال عدة عقود تم تقديم منظومات قادرة على الحل، وحُوّلت بنجاح إلى مجال الصناعة. تتألف البنية الداخلية لـــ ANNs من سلسلة من PE متصلة فيما بينها بنفس اتصال الخلايا العصبونية البيولوجية. تكمن إمكانيات ANNs لحل المشاكل ليس فقط في نوع وعدد PE، بل وأيضاً في شكل الاتصال البيني. يوجد هناك العديد من الدراسات حول تطوير بنية PE، وأيضاً حول أَمْثَلة خوارزميات تعليم ANNs المسؤولة عن ضبط قيم الاتصالات. تعالج هذه الأعمال القيدين الحاليين لـــ ANN الناتجين عن حقيقة أنه لا يوجد أساس رياضي لحساب البنية الهندسية المُثلى لـــ ANNs. ومن جهة أخرى، فإن الخوارزميات المتوفرة لتعليم ANNs تمتلك – في بعض الحالات – مشاكل تقارب بحيث يصبح زمن التدريب كبيراً جداً.

بعض ANNs الأكثر أهمية كتلك التكرارية (recurrent ANNs (Haykin, 1999) (RANNs) تعالج المشاكل الزمنية الشائعة جداً في العالم الحقيقي والمختلفة عن النوع الكلاسيكي لمسائل التصنيف غير الزمني المنجزة بواسطة ANNs استاتية. على أية حال، فلقد حثت صعوبات تنفيذ هذه الشبكات على استخدام الحيل كالتأخيرات (TDNN) أو الشبكات أمامية الانتشار من شبكات تكرارية (BPTT) لحل المشاكل الديناميكية. تعمل RANNs التي تستخدم RTRL مع الظواهر الديناميكية أفضل من ANN الكلاسيكية، على الرغم من أنها ما تزال تعاني من بعض المشاكل في التصميم والتقارب أثناء التدريب.

فيما يتعلق بالمشكلة الأولى من هذه المشاكل والمتمثلة بتصميم البنية الهندسية للشبكة – في كلا نموذجي ANN أمامية الانتشار والتكرارية – فإن وجود مقدار كبير جداً من الإمكانيات التصميمية يسمح بالتجريب،ولكنه يطلق أيضاً الشك حول ماهية التوليفة الأفضل بين التصميم وبارامترات التدريب. لسوء الحظ لا يوجد أساس رياضي يمكن أن يعيد اختبار بنية هندسية معينة، ولكن هناك عدد قليل من الأبحاث (Lepedes & Faber, 1998; Cybenko, 1989)، التي بينت الحدود السفلية والعلوية لعدد PEs في بعض النماذج، ولأنواع مقيدة من المشاكل. عدا تلك الأبحاث يوجد فقط دراسات تجريبية (Yee, 1992) حول هذا الموضوع. نتيجةً لهذا الوضع، لا يمكن القول بشكل أكيد بأن البنية الهندسية المختارة هي الأكثر ملاءمة بدون إجراء اختبارات بنيوية. ومع ذلك، يوجد في أيامنا الحالية تفرع ثنائي الشعب واضح بين ANNs التكرارية وغير التكرارية، ليس فقط فيما يتعلق بالمشاكل التي تُستخدم لحلها، بل وأيضاً بالطريقة التي تُدرب بها الشبكة في كل حالة. لتبرير هذه المشكلة وجعل عملية التصميم آلية، تم تطوير عدة طرق ملائمة من أجل البنية الهندسية لنماذج ANN محددة. تعتمد هذه الطرق على تشذيب الاتصال (Gomm, Weerasinghe, & Willians, 1998; Setiono, 1997).

وتعتمد الطرق الأخرى على زيادة أو تقليل عدد PEs وجميعها من النوع التكراري (Martinetz, Berkovich, & Schulten, 1993, Fritzke, 1995). تسقط جميع هذه الطرق في نهايات صغرى محلية، لأن الشبكات تخلق PE جديدة عندما تستقبل مدخلات مختلفة وهي مستقلة تماماً عن المرحلة الابتدائية للشبكة وأيضاً عن التدريب الذي تُستقبل فيه أنماط تدريبية.

فيما يتعلق بتدريب ANNs، فإن الخوارزميات التقليدية المعتمدة على الهبوط المتدرج حساسة جداً للنهايات الصغرى المحلية لفضاء البحث. وأكثر من ذلك، فمن أجل تحقيق تقارب الشبكة، يجب على المصمم أن يُشكل مجموعة أخرى من البارامترات التي تُضمّن في التدريب مثل معدل التعليم والبارامترات الفردية التي تنتمي لكل خوارزمية. المشكلة الداخلية الأخرى لجميع خوارزميات التعليم هي أنها غير قابلة للتكيف بسهولة لتعديلات العمل لكل PE والاتصالات. وبالتالي، فإن ذلك سيمنع تطوير وتطبيق الميزات الجديدة والتحسينات في نماذج ANNs.

يمكن أن تكون إحدى التحسينات الممكنة هي إدماج بيولوجية مشابهاً لتلك الميزات الخاصة بالخلايا العصبية الطبيعية من أجل فهم أفضل للأداء الوظيفي للعصبونات الصنعية. إن استخدام تقنيات أَمْثلة جديدة هو حل ممكن لهذه المشاكل.

إن الخوارزميات الوراثية (GA) (Fogel, Foyel, & Porto, 1990, Yao, 1992) هي تقنيات سهلة التوظيف لــ EC التي تحقق نتائج جيدة، وقد تم تطبيقها - بالإضافة إلى تقنيات EC أخرى - للضبط البنيوي لسنوات (Robbins, Hughes, Plumbley, Fallside & Prager, 1993)، لدرجة أنها تمثل مجالاً مفتوحاً للبحث. أما الأعمال المتعلقة بتدريب ANNs بوساطة GA فهي قديمة تماماً(Whithey, Starkweather, & Bogart, 1990). تمتلك طريقة التدريب هذه بعض الأفضليات على التقنيات التقليدية المعتمدة على التدرج لأنها أقل حساسية للنهايات الصغرى المحلية بفضل أخذ عيناتها الأفضل لفضاء البحث لجميع أوزان اتصالات الشبكة. يمكن مزج طريقتي التدريب في خوارزمية لامبارك الوراثية بحيث تُطبق أولاً المعاملات الوراثية على المجتمع من أجل الحصول على نسل من كل جيل، وبعد ذلك تُنفذ عدة حلقات تدريب مع خوارزمية الهبوط المتدرج قبل تقييم كل نسل جديد على حدة (أو مجموعة الأوزان). تؤمن هذه الطريقة استخدام جيد لاستكشاف GA، وتتجنب مشكلة النهايات العظمى المحلية عن طريق استخدام طرق الهبوط المتدرج.

أخيراً، يسمح التدريب بوساطة GA بتعديل أداء PE والاتصالات في اتجاه واحد مع تبديل فقط لتابع التقييم. في هذه الحالة لا يتأثر أداء عناصر الشبكة بأداء خوارزمية التعليم. تسمح هذا الاستقلالية بدمج كان صعباً جداً للميزات الجديدة أثناء استخدام خوارزميات التدرج.

الاقتراح

تقترح هذه المقالة تصميم منظومة بالاعتماد على تصميم متعدد المستويات مع ملاءمة متقدمة، بحيث تكون قادرة على العمل، مثل الشبكات العصبية الطبيعية. يعتمد المخطط المقترح على استخدام مستويات عدة لتقنيات (Bramlette, 1991 ،Bethke, 1981 ،Holland, 1975; Bäck, 1996). سوف تُستخدم GA وبشكل خاص في مستويين من أجل تحقيق - بطريقة فعالة وسريعة - اتحاد البارامترات لكلٍّ من البنية في المستوي العلوي والتدريب في المستوي السفلي. السمة الأخرى المأخوذة بعين الاعتبار هي تضمين ميزات جديدة في ANN. ومن أجل إثبات أن النموذج يعكس هذه الإمكانية، تم اقتراح تعديل متعلق بأداء PE. إن الحقيقة التي تعتبر أن PE هو فقط عبارة عن عقدة تعطي خرجاً متعلقاً بقيم الدخل، هي تبسيط كبير لسلوك العصبونات البيولوجية. تم في هذا العمل اقتراح إضافة مركب زمني إلى توابع التفعيل كتعديل لأداء PE بغرض زيادة قدرة ANN عن طريق دراسة الأدلة والشواهد البيولوجية. تحاول هذه التعديلات تقليد إثارة العصبون الطبيعي الذي يُحرّض بكمون الفعل وفترات المقاومة اللاحقة. علاوة على ذلك، يُرافق هذا التعديل بتعقيد كبير لتطوير وتدريب ANN والناجم عن إضافة بارامترات جديدة تؤثر على أداء المنظومة.
تُنفذ تنبؤ سلاسل زمنية كلاسيكية في المجال الإحصائي لإثبات فعالية التعديلات المقترحة. تمت مقارنة هذه النتائج مع تلك التي تم الحصول عليها عندما تُنفذ التنبؤ بعدد من ميزات السلاسل مع نماذج ARIMA (مُعاودة ثنائية الاتجاه) (Box, 1976; Wei, 1990).

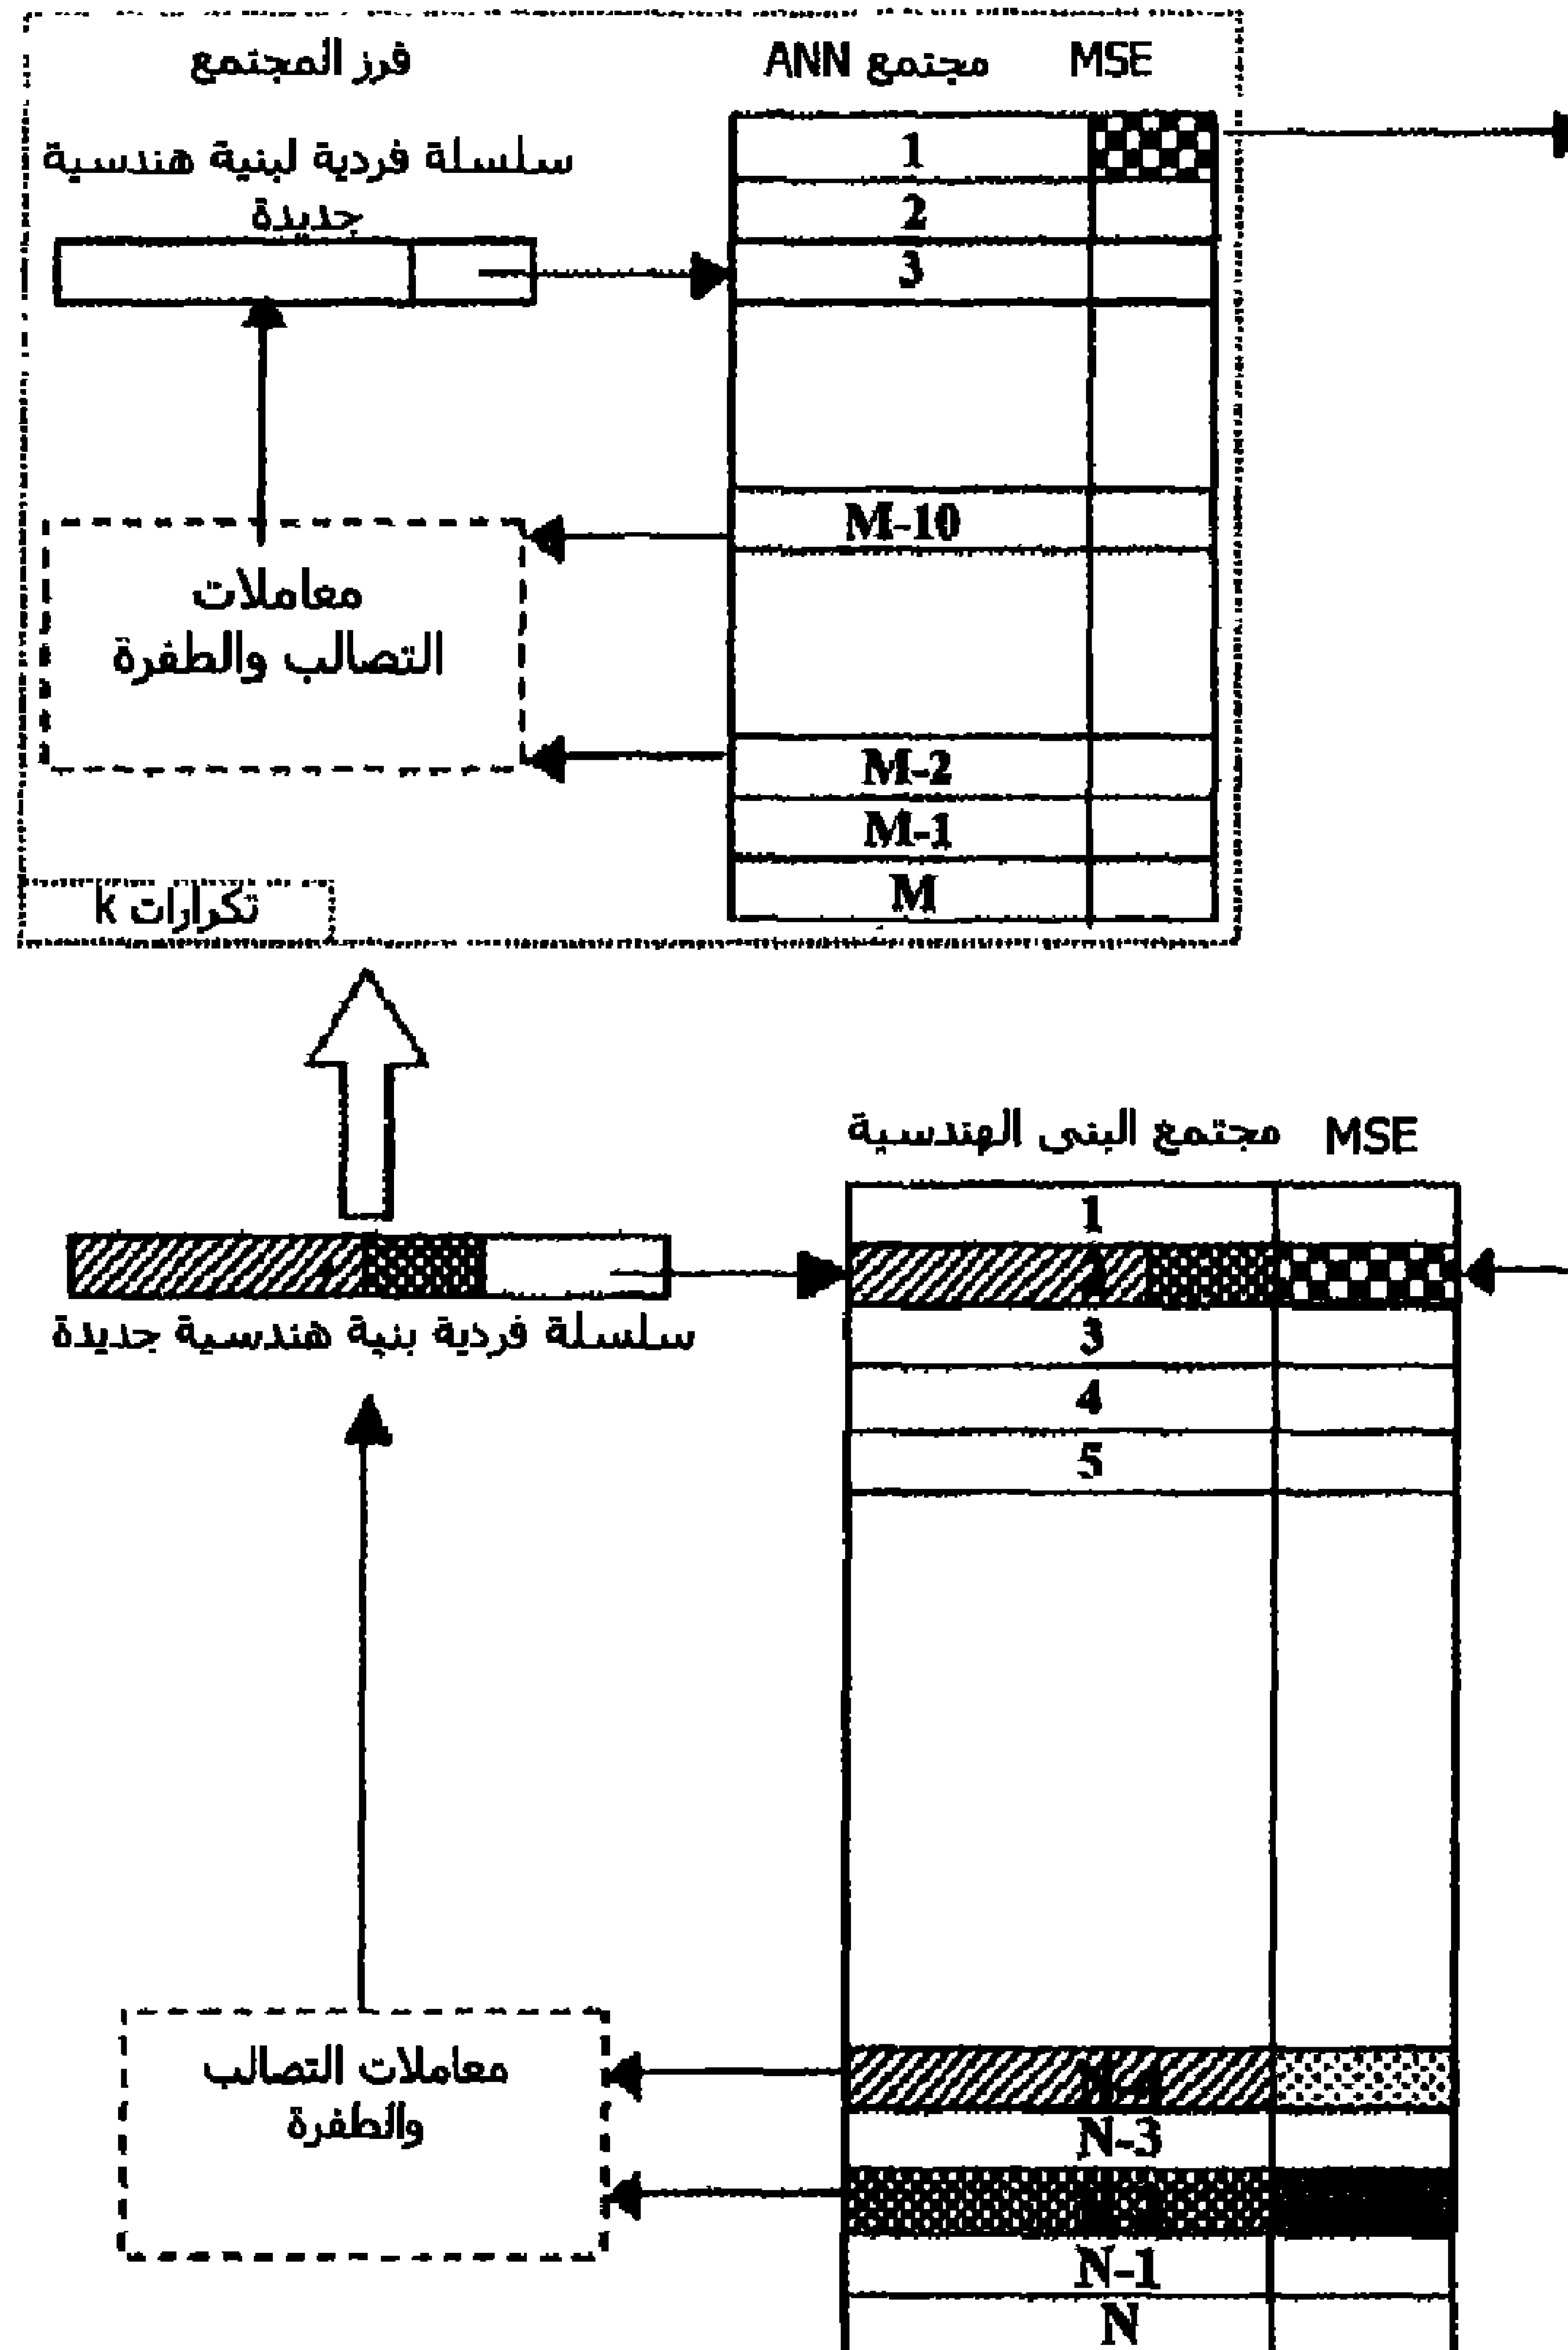
تطوير متعدد المستويات لـ ANNs مع تفعيل زمني موهن

أتمتة التطوير الطبولوجي

تحاول المنظومة المبينة هنا، أن تكون شاملة وعامة قدر الإمكان، حيث أنها تعمل مع ANNs ذات الانتشار الأمامي، وكذلك مع RANNs. تُعنى دراسة ANNs باتصالاتها التي تأخذ بعين الاعتبار تشكيلات مختلفة للطبقات الخفية أخذةً بالحسبان عدد العصبونات فيها (Whitley et at., 1990). بقدر ما تكون RANN معينة، فإن ضبط البنية الهندسية سيتضمن حساب العدد المثالي للعصبونات الخفية واتصالاتها. تكون المصفوفات الاتصالية مثلثية علوية في ANN ذات انتشار أمامي، ولكن مع قيم تخزين كامل المصفوفة للحفاظ على التوافق مع RANN. يجب أن نتذكر دائماً، بأن وجود المصفوفة الاتصالية، يؤثر في طريقة تقييم ANNs بما أن حساب مدخلات كل PE يجب أن يأخذ بالحسبان المصفوفة الاتصالية المرافقة لكل شبكة.

تستخدم المنظومة GA من أجل تصميم ضبط البنية الهندسية. تقدم GA هذه اختلافات ملحوظة بالمقارنة مع GA القياسية نتيجة للتشكيل الخاص للمشكلة المطلوب حلها (الشكل 1)، مجتمع البنى الهندسية). أولاً، المعلومات المُجمعة حول ANN (البنية الهندسية، الاتصالية، توابع تفعيل PE) ليس لها طول ثابت، وهي تعتمد على نوع ANN. وبالتالي، فإنه من الضروري استخدام GA مع سلاسل فردية بأطوال مختلفة. ثانياً، من الضروري ضبط ثلاثة أنواع من البارامترات بشكل آني. يحدث هذا الأمر تعديلات في معادلات التصالب والطفرة. وهو يتعامل مع سلاسل فردية لثلاثة أنواع مختلفة من الواصفات. ثالثاً، يجب أن يُنفذ تقييم السلاسل الفردية بتلبيس ANN للمشكلة المراد حلها (الشكل 11، مجتمع ANNs).

الشكل (1) *المخطط العام لأداء المنظومة.*



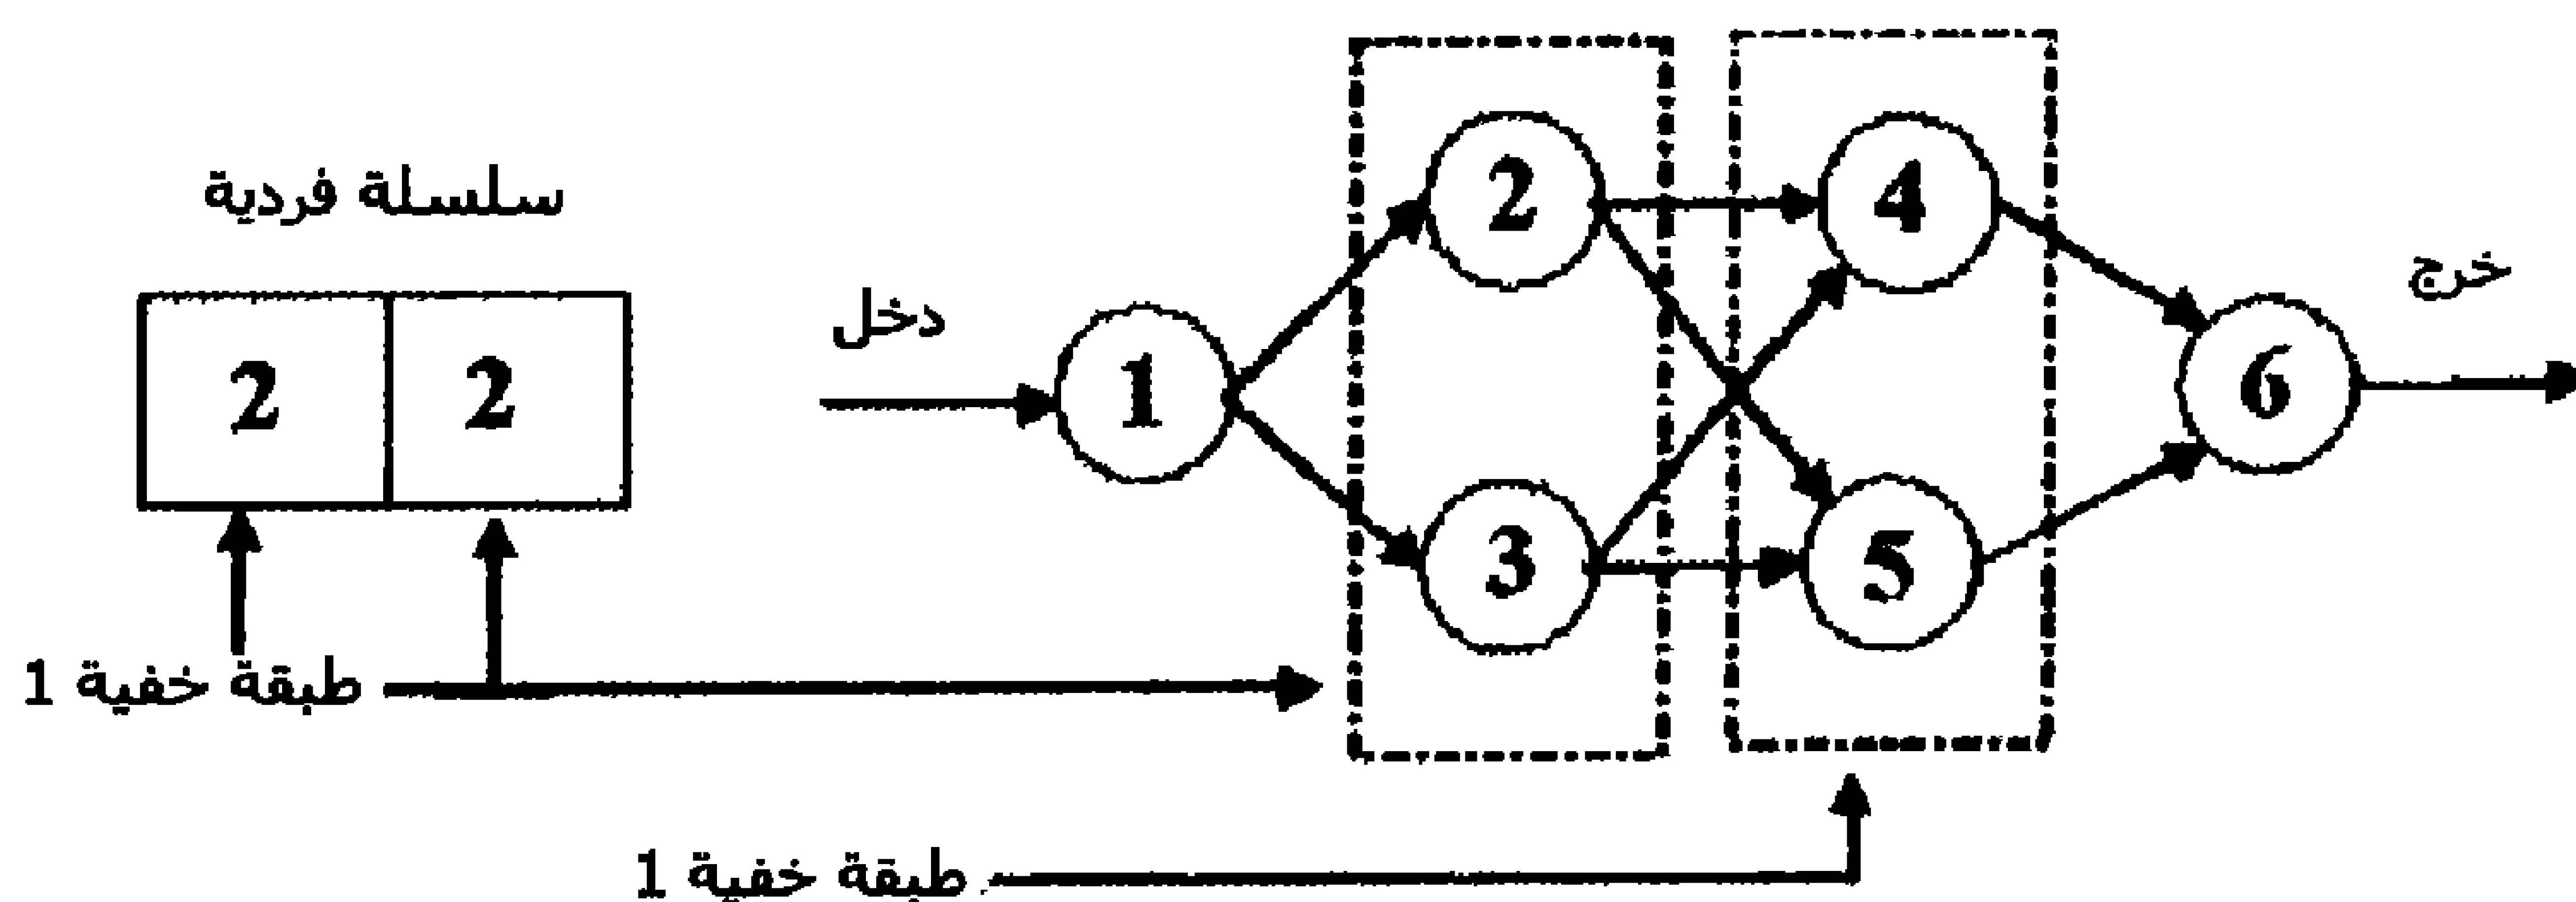
تشكيل GA

ترميز السلسلة الفردية

من الضروري التمييز بين الشبكات أمامية الانتشار والشبكات التكرارية. بدايةً، يجب تشكيل كل من عدد الطبقات الخفية وعدد PE في كل طبقة. ولتحقيق ذلك، تجمع GA السلاسل الفردية في مصفوفة يمثل كل موقع فيها عدد العصبونات في الطبقة الخفية (انظر الشكل 2). من الواضح بأن هذه السلاسل الفردية سيكون لها طول متغير، طالما أنه سيكون هناك سلاسل فردية مع عدد مختلف للطبقات الخفية. سيتم تشكيل قيمة عظمى لعدد الطبقات من أجل تجنب تطوير ANN إلى حجم غير متوازن. تمتلك السلاسل الفردية في RANN فقط المواقع المتعلقة بعدد العصبونات الخفية.

في كل سلسلة فردية، سيكون هناك مصفوفة اتصالية بين العصبونات. تشير هذه المصفوفة إلى ماهية الاتصالات التي ستُضبط خلال مرحلة التدريب، بحيث يقصد بـــ "1" بوجود اتصال، بينما يعني الـــ "0" عدم وجود اتصال (قيمة الصفر هي من أجل وزن الاتصال). تستخدم ANNs أمامية الانتشار مصفوفة مثلثية علوية تسمح بالاتصالات بين عصبونات الطبقات غير المتتالية فقط إذا كانت هذه الاتصالات باتجاه طبقات لاحقة.

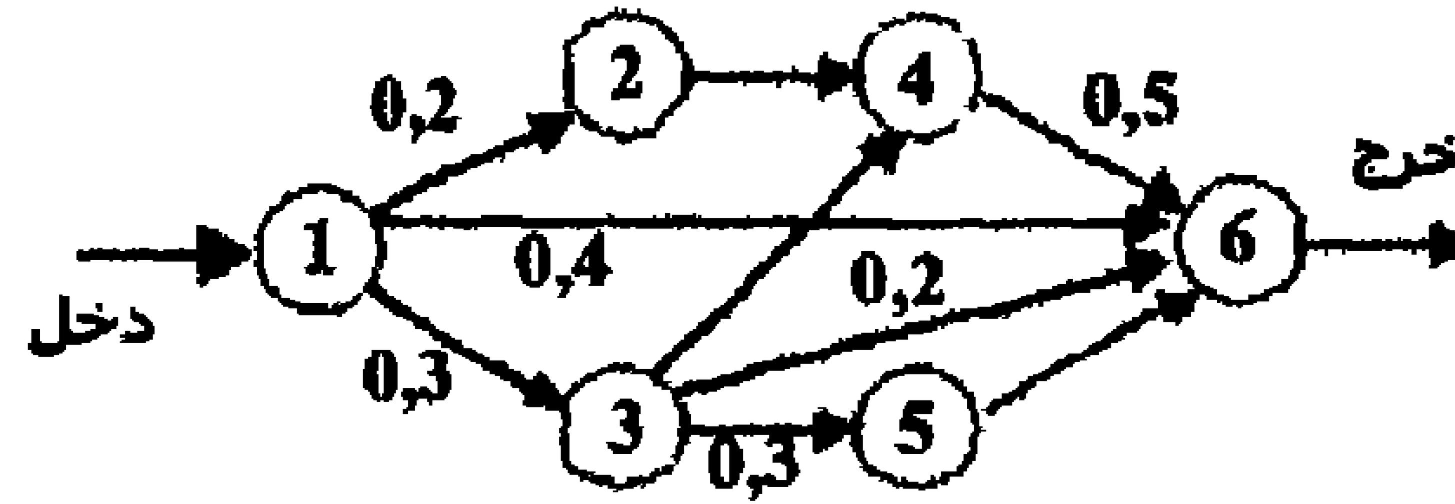
الشكل (2) الترميز البنيوي للطبقات والعصبونات في ANN لا تكرارية



كما هو واضح في (الشكل 3) تربط مواقع المصفوفة (1,6) و(3,6) عناصر طبقات غير متتالية. المواقع الموهنة في مصفوفة (الشكل 3) هي غير ممكنة بما أنها تمثل الاتصالات المعاودة والشبكة المراد استخدامها هي ذات انتشار أمامي. أخيراً. في تلك المواقع التي قيمها غير موهنة، يمكن أن تُستخدم كافة التوليفات الممكنة بحيث ستزيل GA تلك البنى الهندسية غير القابلة للتطبيق مع عصبونات الخرج أو مع عصبونات الدخل.

الشكل (3) *الاتصالية في ANN أمامية الانتشار*

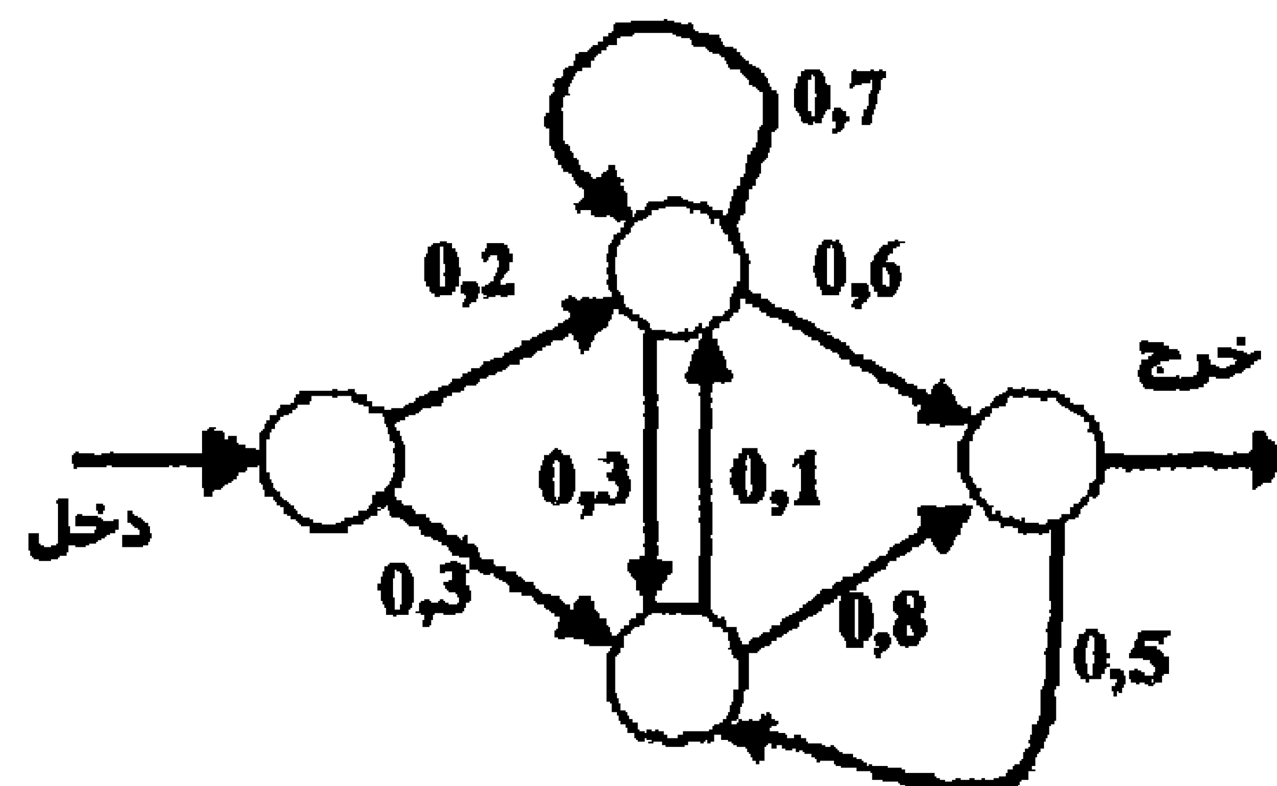
PE	1	2	3	4	5	6
1	0	1	1	0	0	1
2	0	0	0	1	0	0
3	0	0	0	1	1	1
4	0	0	0	0	0	1
5	0	0	0	0	0	1
6	0	0	0	0	0	0



تُوصف اتصالية RANN بوساطة المصفوفة الكاملة. في هذه الحالة، لا توجد قيود على الاتصالية. وبالتالي، لا توجد اتصالات ذات قيم موهنة. هنا، تسمح المصفوفة باختيار الاتصالات الهامة باتجاه العصبونات السابقة واللاحقة، كذلك باتجاه العصبونات نفسها (الشكل 4).

الشكل (4) *الاتصالية في RANN*

PE	1	2	3	4
1	0	1	1	0
2	0	1	1	1
3	0	1	0	1
4	0	0	1	0



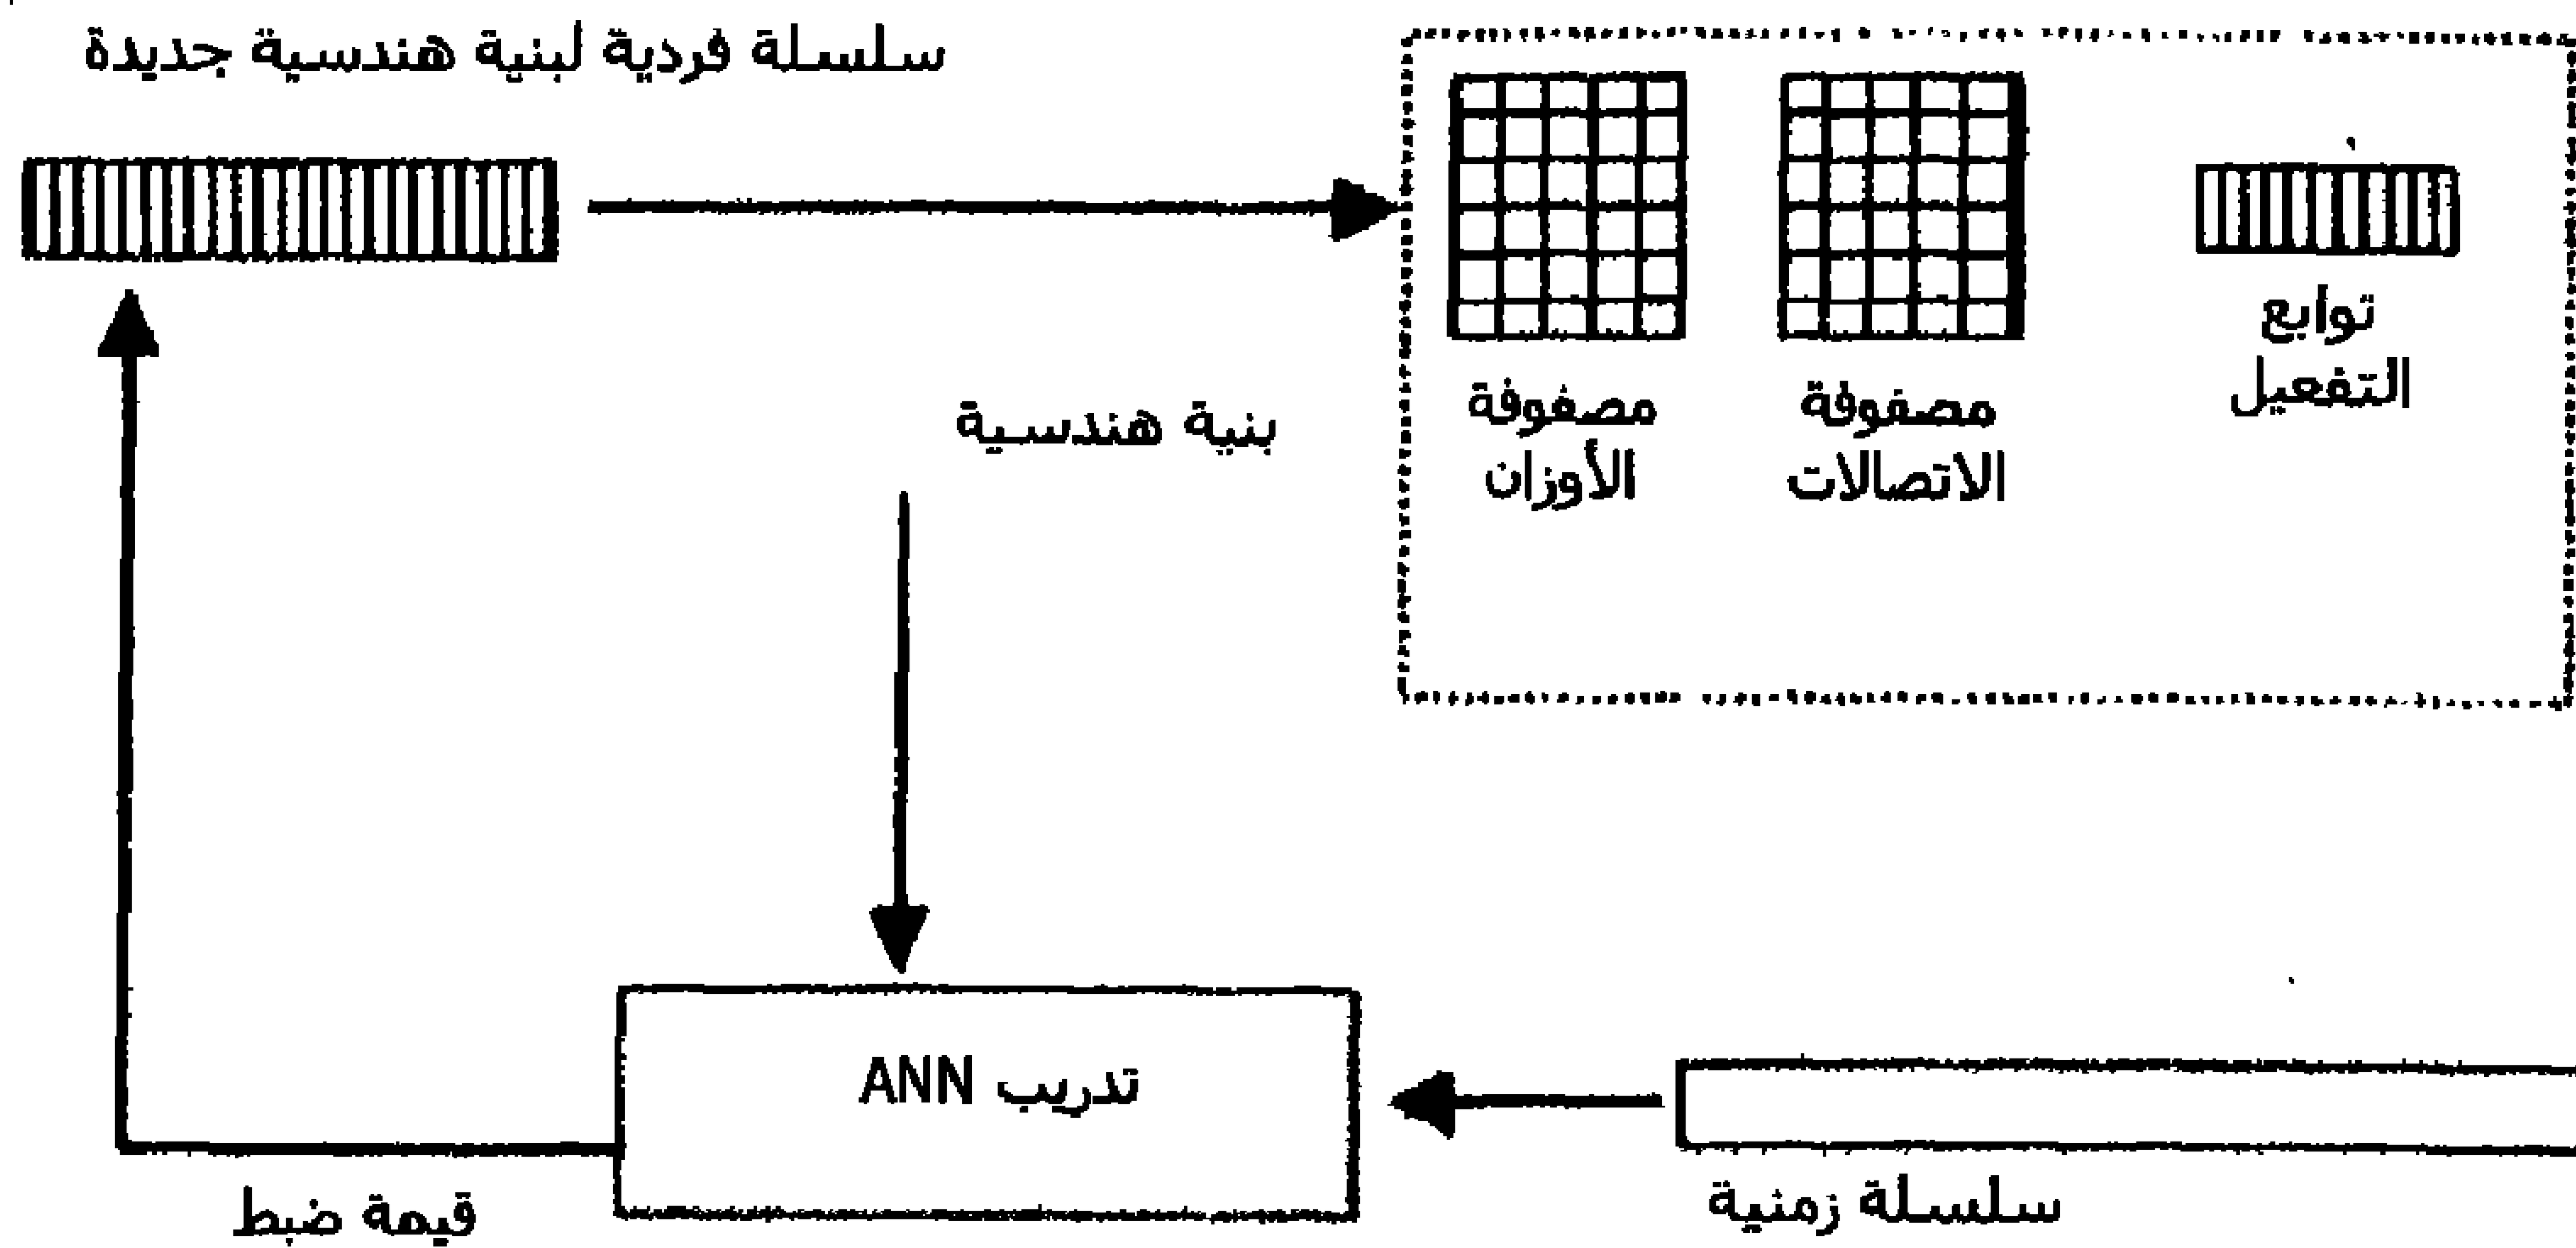
يجب أن تملك مصفوفة توابع التفعيل مواقع عديدة بعدد العصبونات ليس فقط من أجل تحديد نوع التابع الذي سيُستخدم (خطي L، سيغمويد S، ظلي ذو قطع زائد أو عتبي U)، بل أيضاً من أجل تخزين تلك البارامترات العائدة لتابع التفعيل الخطي (ميل الخط المستقيم)، والعائدة إلى العتبة (قيمة العتبة).

معاملات التصالب والطفرة

السلاسل الفردية مركبة من ثلاثة أقسام: عدد العصبونات، والاتصالات، وتابع التفعيل لكل عصبون. تُجمع هذه الأقسام الثلاثة في صبغي بطول متغير. تفرض عملية التصالب، بأن هذه الأقسام الثلاثة مستقلة عن بعضها البعض، بالتالي فهي تحتاج لثلاث نقاط تصالب من أجل أن يرث كل سليل من النسل قسماً من المعلومات الوراثية للسلف في كل من المفاهيم الثلاثة. وبالتالي، فهذا الأمر مشابه لتطبيق ثلاث خوارزميات تصالب عامة بشكل آني، بحيث تكون خوارزمية واحدة لكل نوع من المعلومات. يُنفذ كل تصالب من هذه التصالبات باستخدام سلسلة فريدة واحدة مختارة عشوائياً بين المجتمع الكامل مع سلسلة فردية أخرى من النصف الأفضل للمجتمع. يُنفذ هذا الأمر بغية تجنب تجانس المجتمع الناتج عن التصالب المستمر للسلاسل الفردية الأفضل. حققت هذه الاستراتيجية أفضل النتائج على الإطلاق، بما أنها لا تأخذ أفضلية السلاسل الفريدة الأحسن تكيفاً، وهي تؤمن استخداماً جيداً لأية سلسلة فردية من المجتمع. تُقيَّم السلسلتان خلال الطور الأخير، ويتم ضم النسل الأفضل فقط إلى المجتمع. ومن أجل ضبط الفضاء، تغادر السلسلة الأسوأ تكيفاً المجتمع الأصلي بعد إزالتها.

يطبق معامل الطفرة تعديلات على عدد محدود من السلاسل الفردية للمجتمع في مواقع عشوائية. ومع ذلك، فمن الضروري في هذه الحالة الأخذ بالاعتبار بأن الأقسام الثلاثة للصبغي تستخدم مجالات مختلفة للقيم. تمثل المورثات في القسم الأول عدد العصبونات، كما يوجد عدد أعظمي من العصبونات الخفية. وفي القسم الثاني، تمثل المورثات الاتصالية بين Pes، ويمكنها أن تأخذ قيمتين فقط "0" أو "1". أخيراً، يمثل القسم الثالث توابع التفعيل لكل عصبون، ويمكن أن يأخذ فقط أحد الأنواع الأربعة المطبقة في المنظومة. نتيجةً لهذه الخواص، وبعد الاختيار العشوائي للمورثة التي ستكون الطفرة ضمن سلسلة فردية ما، يصبح من الضروري اختيار المنطقة أو المكان الذي ستنتمي إليه من أجل توليد قيمة ضمن المجال الموافق للقيم. بعد ذلك، يُعاد تقييم السلسلة الفردية التي حدثت فيها الطفرة، ثم يعاد تعيينها في المجتمع على أنها متعلقة بشكل عادي بمعامل الطفرة.

الشكل (5) مخطط تقييم البنية الهندسية لـ ANN.



التقييم

من أجل تقييم السلاسل الفردية لــ GA تنفذ الخوارزمية التدريب لــ RANN، التي تُحقق قيود العصبونات وعدد PEs والاتصالات وتوابع التفعيل لكل سلسلة فردية في المجتمع لتحقيق مستوي الضبط، الذي يعطي نقيضاً لحل مسألة معينة. تُجمع هذه المعلومات في سلاسل فردية لــ GA لمستوي التصميم، وتمرر كدخل لعملية التدريب بوساطة GA أخرى. تُستخدم قيمة الملاءمة الناتجة خلال عملية التدريب كمقياس للضبط في GA لمستوي التصميم. تنفذ خوارزمية التدريب الوراثية دائماً العدد نفسه من التوليدات لتقييم كافة البنى الهندسية لتكون قابلة للمقارنة. وما إن يُحقق هذا العدد، فإن قيمة الخطأ الناتجة بواسطة ANN خلال مرحلة التدريب ستمثل مستوي الملاءمة للبنية الممثلة.

يجب الأخذ بالحسبان بأن ANNs المدربة، لا تحتاج للبحث عن مستوى خطأ أصغر خلال تقييم البنى الهندسية. يُستخدم التدريب المختزل لــ ANNs لتحقيق قيمة تمثيلية لإمكانيات بنية معطاة. ويصبح في هذه الحالة من المهم جداً تعيين هدف محدد كعدد دورات التنفيذ خلال زمن التدريب. لن يكون تثبيت مستوي الخطأ كهدف فعالاً، بما أن البنية الهندسية يمكن ألا تحقق ذلك المستوي، وبالتالي ستفشل عملية تقييم السلسلة الفردية.

تدريب ANN بواسطة GA

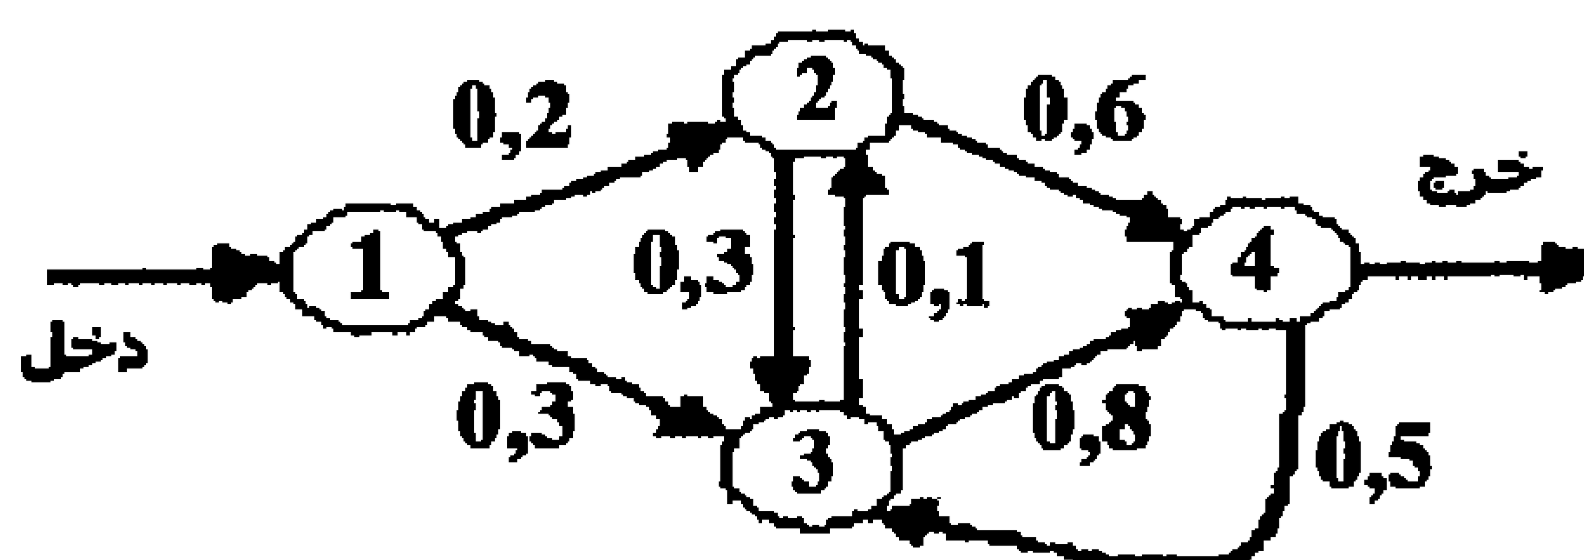
كما شرحنا سابقاً، تحتاج المنظومة المطورة من أجل تقييم سلاسلها الفردية إلى تدريب ANNs. يتم هذا الأمر عن طريق تطوير GA، أخرى التي ستقوم بضبط أوزان الاتصالات. تستخدم تلك

GA بنية هندسية ثابتة لـــ ANN (فيما يتعلق بعدد الطبقات وعدد العصبونات في كل طبقة، وكذلك الاتصالات وتوابع التفعيل) ومعطيات المشكلة.

عند هذه النقطة، تكمن المشكلة في أَمْثَلة الأوزان لـــ ANN بغية تحقيق الحل لمشكلة معطاة. وبالتالي، ستُمثل مورثات السلاسل الفردية بمجموعة أوزان الاتصالات. النقطة المفتاحية من أجل الترميز هي التالية: أن المنظومة قادرة على تدريب ANN أمامية الانتشار وRANN، فمن الضروري اختيار تمثيل يدعم كلا النوعين من الشبكات، بحيث يمكن أن يستخدم نفس النوع من المعلومات الوراثية معهما.

الشكل (6) *مصفوفة الأوزان وANN التي تمثلها*

PE	1	2	3	4
1		0,2	0,3	
2			0,3	0,6
3		0,1		0,8
4			0,5	



متابعةً للفكرة السابقة، تُمثل كل ANN بوساطة مصفوفة بقياس N × N. حيث أن N – هي العدد الكلي للعصبونات في ANN بغض النظر عن الطبقة التي تنتمي إليها. تحتوي هذه المصفوفة على قيم الأوزان فقط من أجل المواقع التي تكون مساوية لـــ 1 في مصفوفة الاتصالية، والتي تكون ثابتة خلال تدريب شبكة محددة. ستكون الخلية ذات الموقع (i, j) عبارة عن الوزن من أجل الاتصال بين خرج العصبون i ودخل العصبون j. إذا لم يكن هناك اتصال مباشر بين العصبونات (j, k) (بسبب وجود قيمة الصفر في مصفوفة الاتصالية، فإن قيمة المصفوفة في الموقع (j.k)) ستكون صفراً فقط. إن مصفوفة الأوزان لــ ANN أمامية الانتشار هي دائماً مثلثية علوية، لأنه لا توجد اتصالات بين عصبونات الطبقة الواحدة، أو مع عصبونات الطبقات السابقة. أما RANN فتستخدم كامل مصفوفة الاتصالات لتوصيف الاتصالات الأمامية والعكسية.

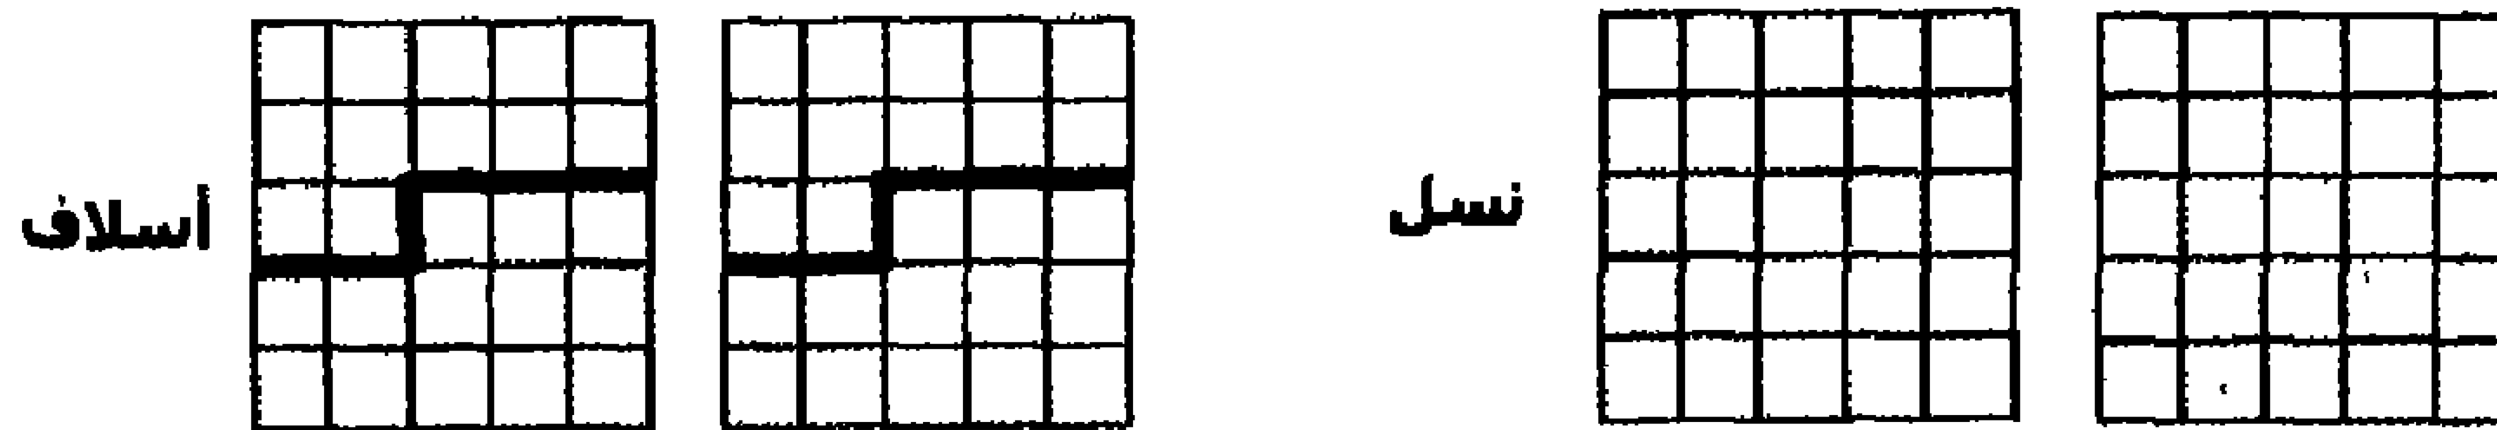
معامل التصالب

بما أن كل سلسلة فردية تتألف من مصفوفة، فإن معامل التصالب يجب أن يُعدّل من أجل مزيج موحد لميزات الأسلاف في النسل خلال عملية التصالب.

في الحالات المشابهة لهذه الحالة، يجب أن يُكيّف المعامل المذكور من أجل تنفيذ مهمته على مصفوفة ثنائية البعد. ويكون الخيار الممكن لتطبيق المعامل هو اختيار خلية من المصفوفة التي يمكن أن تُعتبر كنقطة تصالب (انظر الشكل 7). سوف تنتمي المواقع والسطور السابقة لكلٍّ من تلك الخلية ولسطرها إلى سلسلة فردية من النسل، فيما تنتمي المواقع والسطور اللاحقة إلى سليل آخر. كما يمكن أيضاً اختيار سطر كنقطة تصالب في حالة أكثر عمومية.

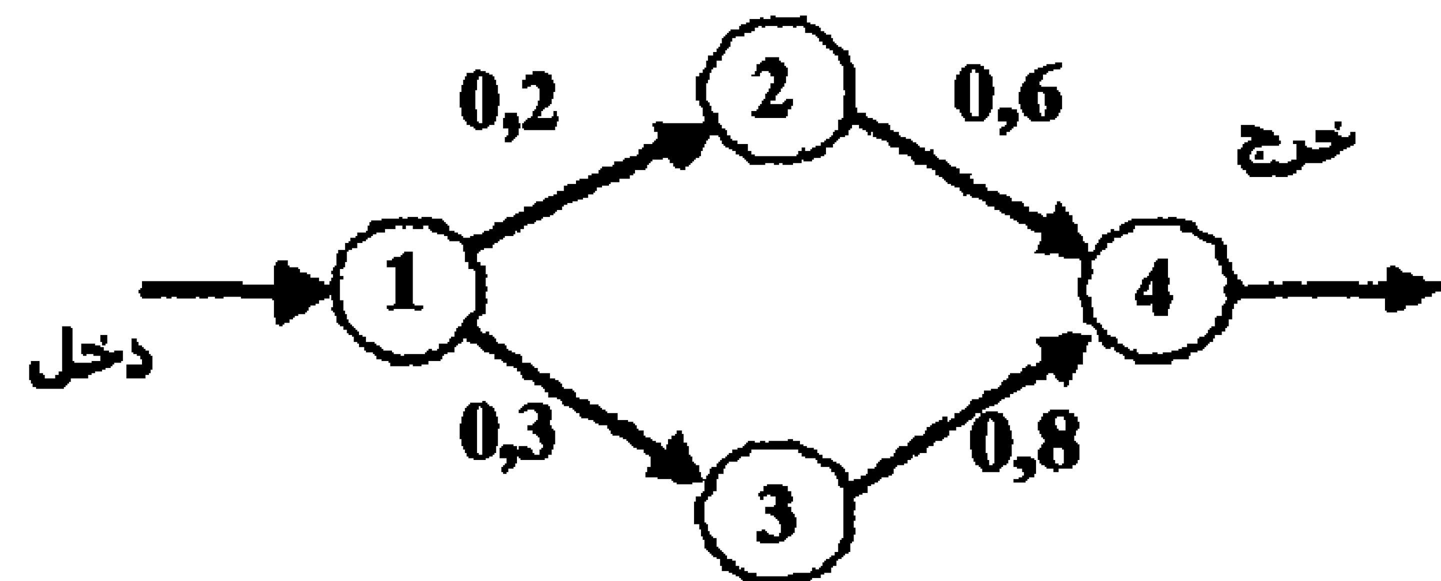
يحدث الخياران السابقان باستخدام سطر أو باستخدام موقع تقسيم أفقي في المصفوفات التي ستكون متصالبة. وكما هو موضح في (الشكل 8)، تُشكل قيم أوزان ANN غير التكرارية مجموعات في القسم العلوي من مصفوفاتها نتيجةً لعدم وجود اتصالات عكسية، بالإضافة للعدد الأعلى للاتصالات مع الطبقة الخفية الأولى. نتيجةً لذلك، ومن أجل انجاز تصالب أكثر تجانساً تُقسم المصفوفة إلى أعمدة، يتم فيها التصالب كما هو مشروح مع السطور (انظر الشكل 9).

الشكل (7) *معامل التصالب من أجل مصفوفات الأوزان*

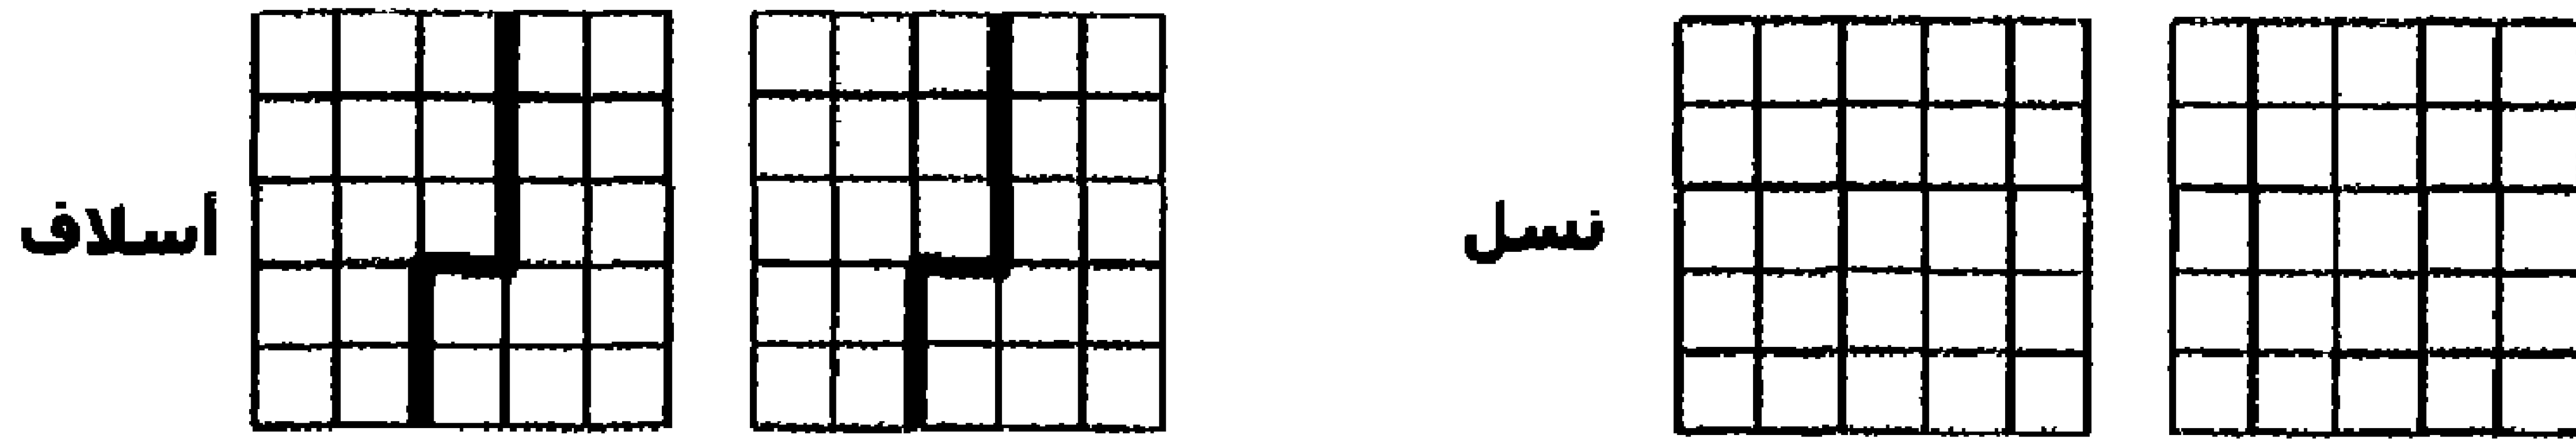


الشكل (8) *مثال على مصفوفة الأوزان لـ ANN غير تكرارية*

PE	1	2	3	4
1		0,2	0,3	
2				0,6
3				0,8
4				



الشكل (9) معامل تصالب شاقولي من أجل مصفوفات الأوزان



إضافة ميزات بيولوجية

العصبون الطبيعي

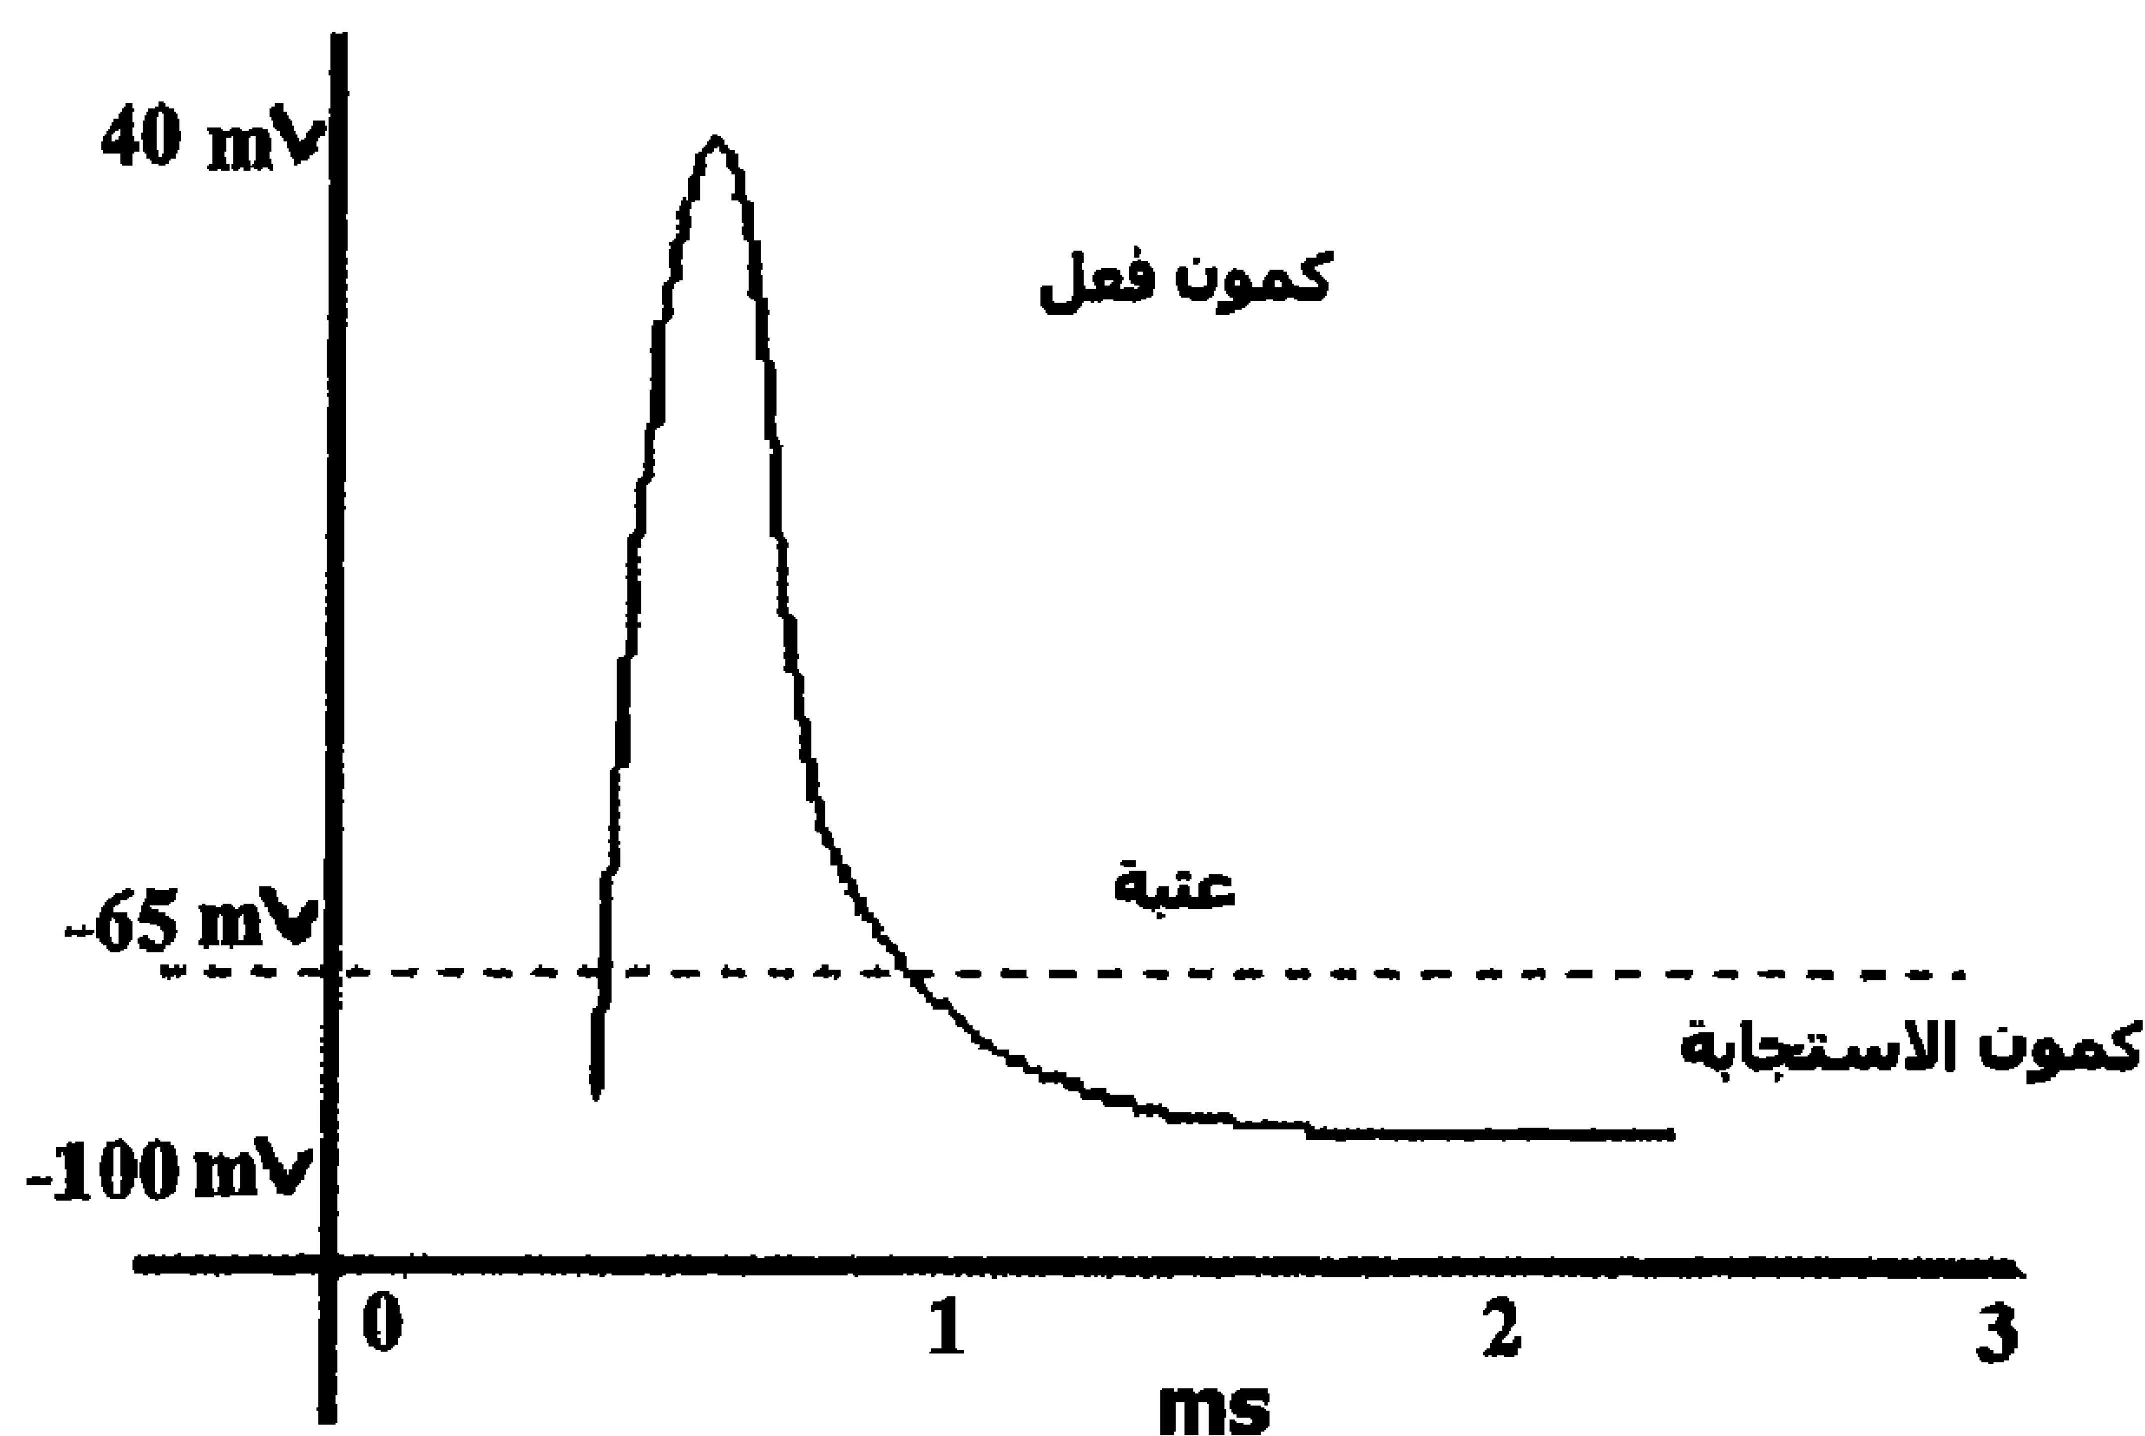
لقد تم شرح خرج تفعيل الخلية العصبونية (العصبون) من المواصفات الكهربائية لغشاء الخلية، وهذا الغشاء أكثر نفاذية لشوارد البوتاسيوم (k+) من شوارد الصوديوم. يُسبّب التدرج الكيميائي للبوتاسيوم انتشار أيونات البوتاسيوم من الخلية، غير أن التجاذب القوي للأيونات العضوية يؤدي إلى إبقاء البوتاسيوم في الداخل. تكون محصلة هذه القوى المتعاكسة هي التوازن، عندما يكون هناك أيونات صوديوم وكلور (cl⁻) أكثر في الخارج وأيونات بوتاسيوم وأيونات عضوية أكثر في الداخل. يحدث هذا التوازن فرق كمون عبر غشاء الخلية تتراوح قيمته بين 70 إلى 100 ميلي فولط، ويصبح السائل الموجود داخل الخلايا سلبياً. يدعى هذا الكمون بالكمون الاستقراري (السكوني) للجهد.

يُضاف تأثير المدخلات الاستثارية الواصلة إلى الخلية من خلية أخرى إلى وصلة المحوار، وتسبب زوالاً متتالياً لاستقطاب الغشاء. بعد ذلك، يُقلب الكمون ليصبح حوالي 35+ ميلي فولط خلال 0.1 ميلي ثانية فقط. تغير إزالة الاستقطاب الناتجة نفاذية الغلاف الخلوي بالنسبة لأيونات الصوديوم. كنتيجةً لذلك، يحدث تدفق داخل أيونات الصوديوم الموجبة التي تدخل إلى الخلية مؤثرةً بشكل كبير على إزالة الاستقطاب. يسبب هذا التأثير المُولّد ذاتياً كمون الفعل (الشكل 10). بعد حدوث كمون الفعل، يصبح كمون الغشاء أكثر سلبيةً من الكمون الاستقراري لبضعة ميللي ثانية، ثم يعود ليحصل على التوازن الأيوني. من أجل البدء بكمون الفعل، يتطلب الأمر زيادة مفاجئة بحوالي 15 إلى 30 فولط آخذين بالحسبان بأن الكمون – 65 – ميلي فولط هو عتبة الإثارة. لا يمكن ضمن ليف قابل للإثارة تحقيق كمون فعل ثانوي، بينما يكون الغشاء مزالاً استقطابياً. الدور الذي لا يمكن خلاله تحرير كمون فعل آخر حتى مع إثارة قوية جداً يدعى بالدور الحراري المطلق، ويدوم حوالي 0.5 ميلي ثانية. يُتبع هذا الدور بدور حراري نسبي، يدوم

حوالي 1 إلى 1.5 ميللي ثانية، حيث يتطلب تحفيزاً أكبر من العادي لتحقيق كمون الفعل، وذلك لأن التوازن الأيوني للكمون الاستقراري لم يُستعد بعد.

لايمكن لهذه النقطة أن تكون مثارة خلال حوالي 1 ميلي ثانية، وهو الزمن اللازم لاستعادة الكمون الاستقراري - يقيد هذا الدور الحراري تردد انتقال النبضة (الدفعة) العصبية ليكون حوالي 1.000 في الثانية.

***الشكل (10)** تحرير كمون الفعل في الغشاء العصبوني*

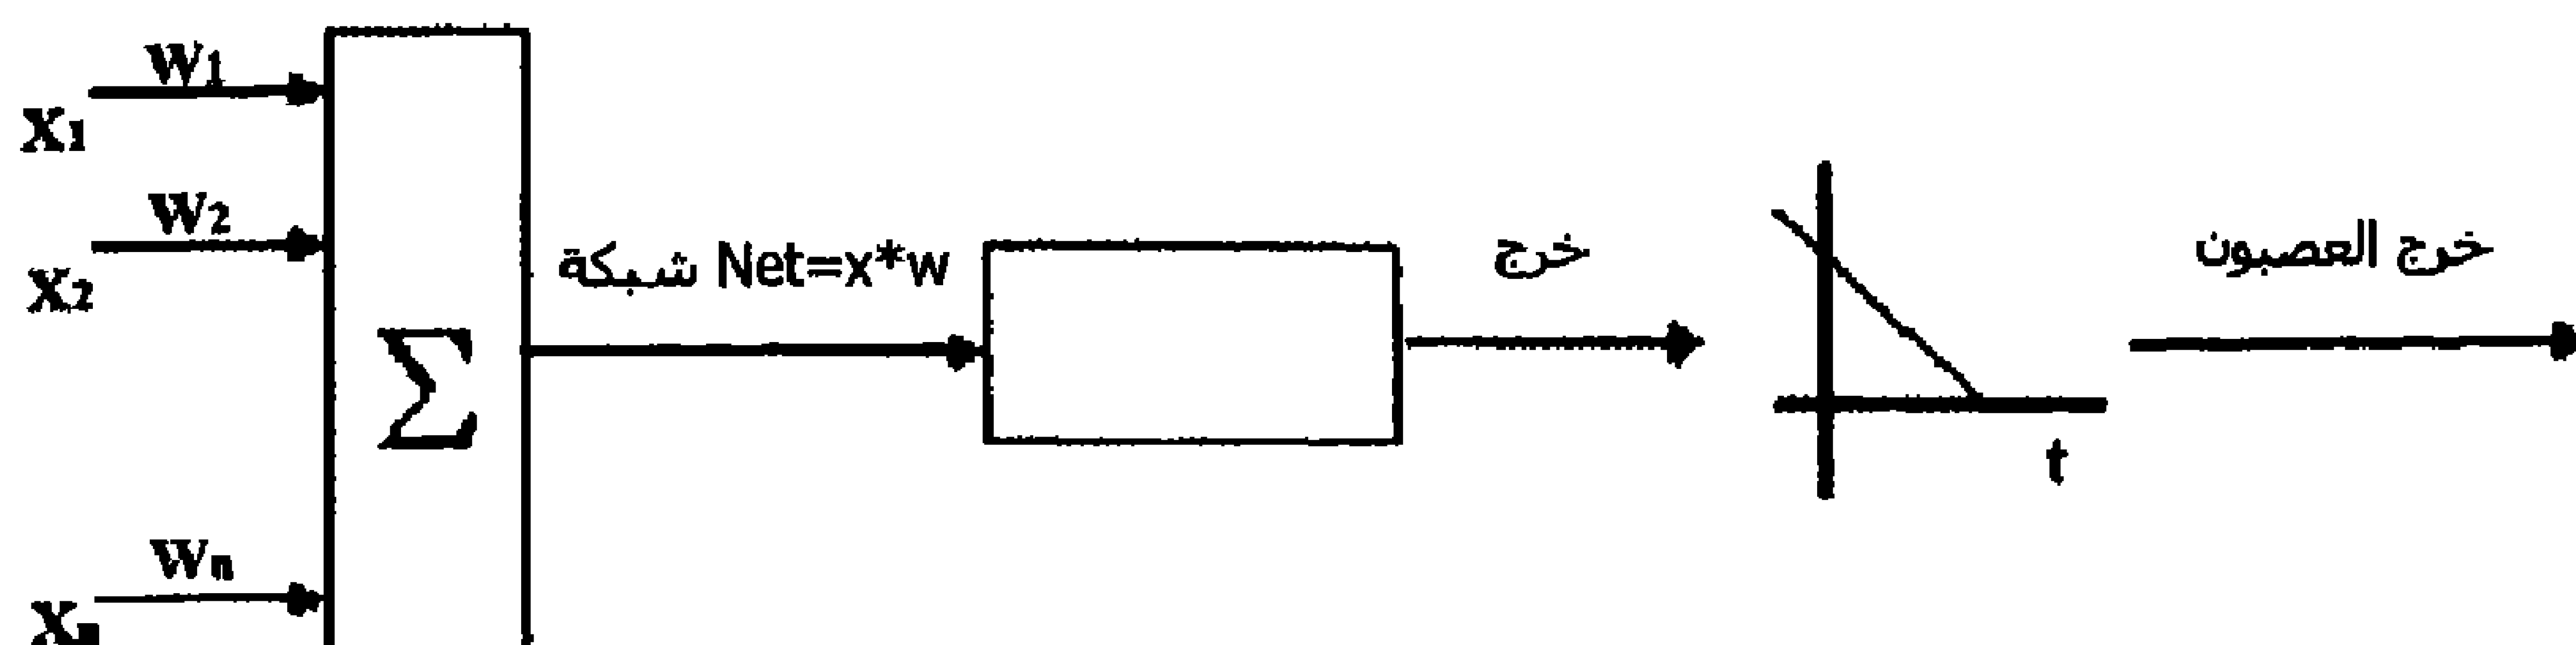


البنية الهندسية مع تفعيل موهن زمنياً

من الواضح أن سلوك PE في ANN ليس شبيهاً جداً فيما يتعلق بطور التفعيل بالسلوك الذي شرحناه للتو. في PE التقليدية، يُطبق تابع تفعيل على توابع الدخل المُثقلة بالأوزان مع تفعيل الطبقة السابقة، وأكثر توابع التفعيل استخداماً هي التابع الأسي وتابع السيغمويد. إذا كان خرج تابع التفعيل موجباً، يحدث عندئذ التفعيل. في تلك اللحظة، سيكون لدى العصبونات التي حصلت على التفعيل دخل يمثل جداء وزن الاتصال بقيمة التفعيل.

تعمل هذه الطريقة لانتشار تفعيل العصبون بأسلوب محافظ على الوقت جداً بدون إعطاء فكرة عن الاستمرارية التي يمكن أن تُشاهد في النموذج الطبيعي، حيث يتدفق التفعيل من نقطة أعظمية (كمون الفعل) إلى أن يصل إلى الصفر (كمون الاستقرار). تم في هذا العمل إضافة تابع كمون الفعل إلى البنية الهندسية الكلاسيكية لـــ PE بتقريبها بواسطة خط يبدأ من مستوي خرج التفعيل إلى المستوي الصفري.

***الشكل (11)** تمثيل التفعيل الموهن زمنياً*



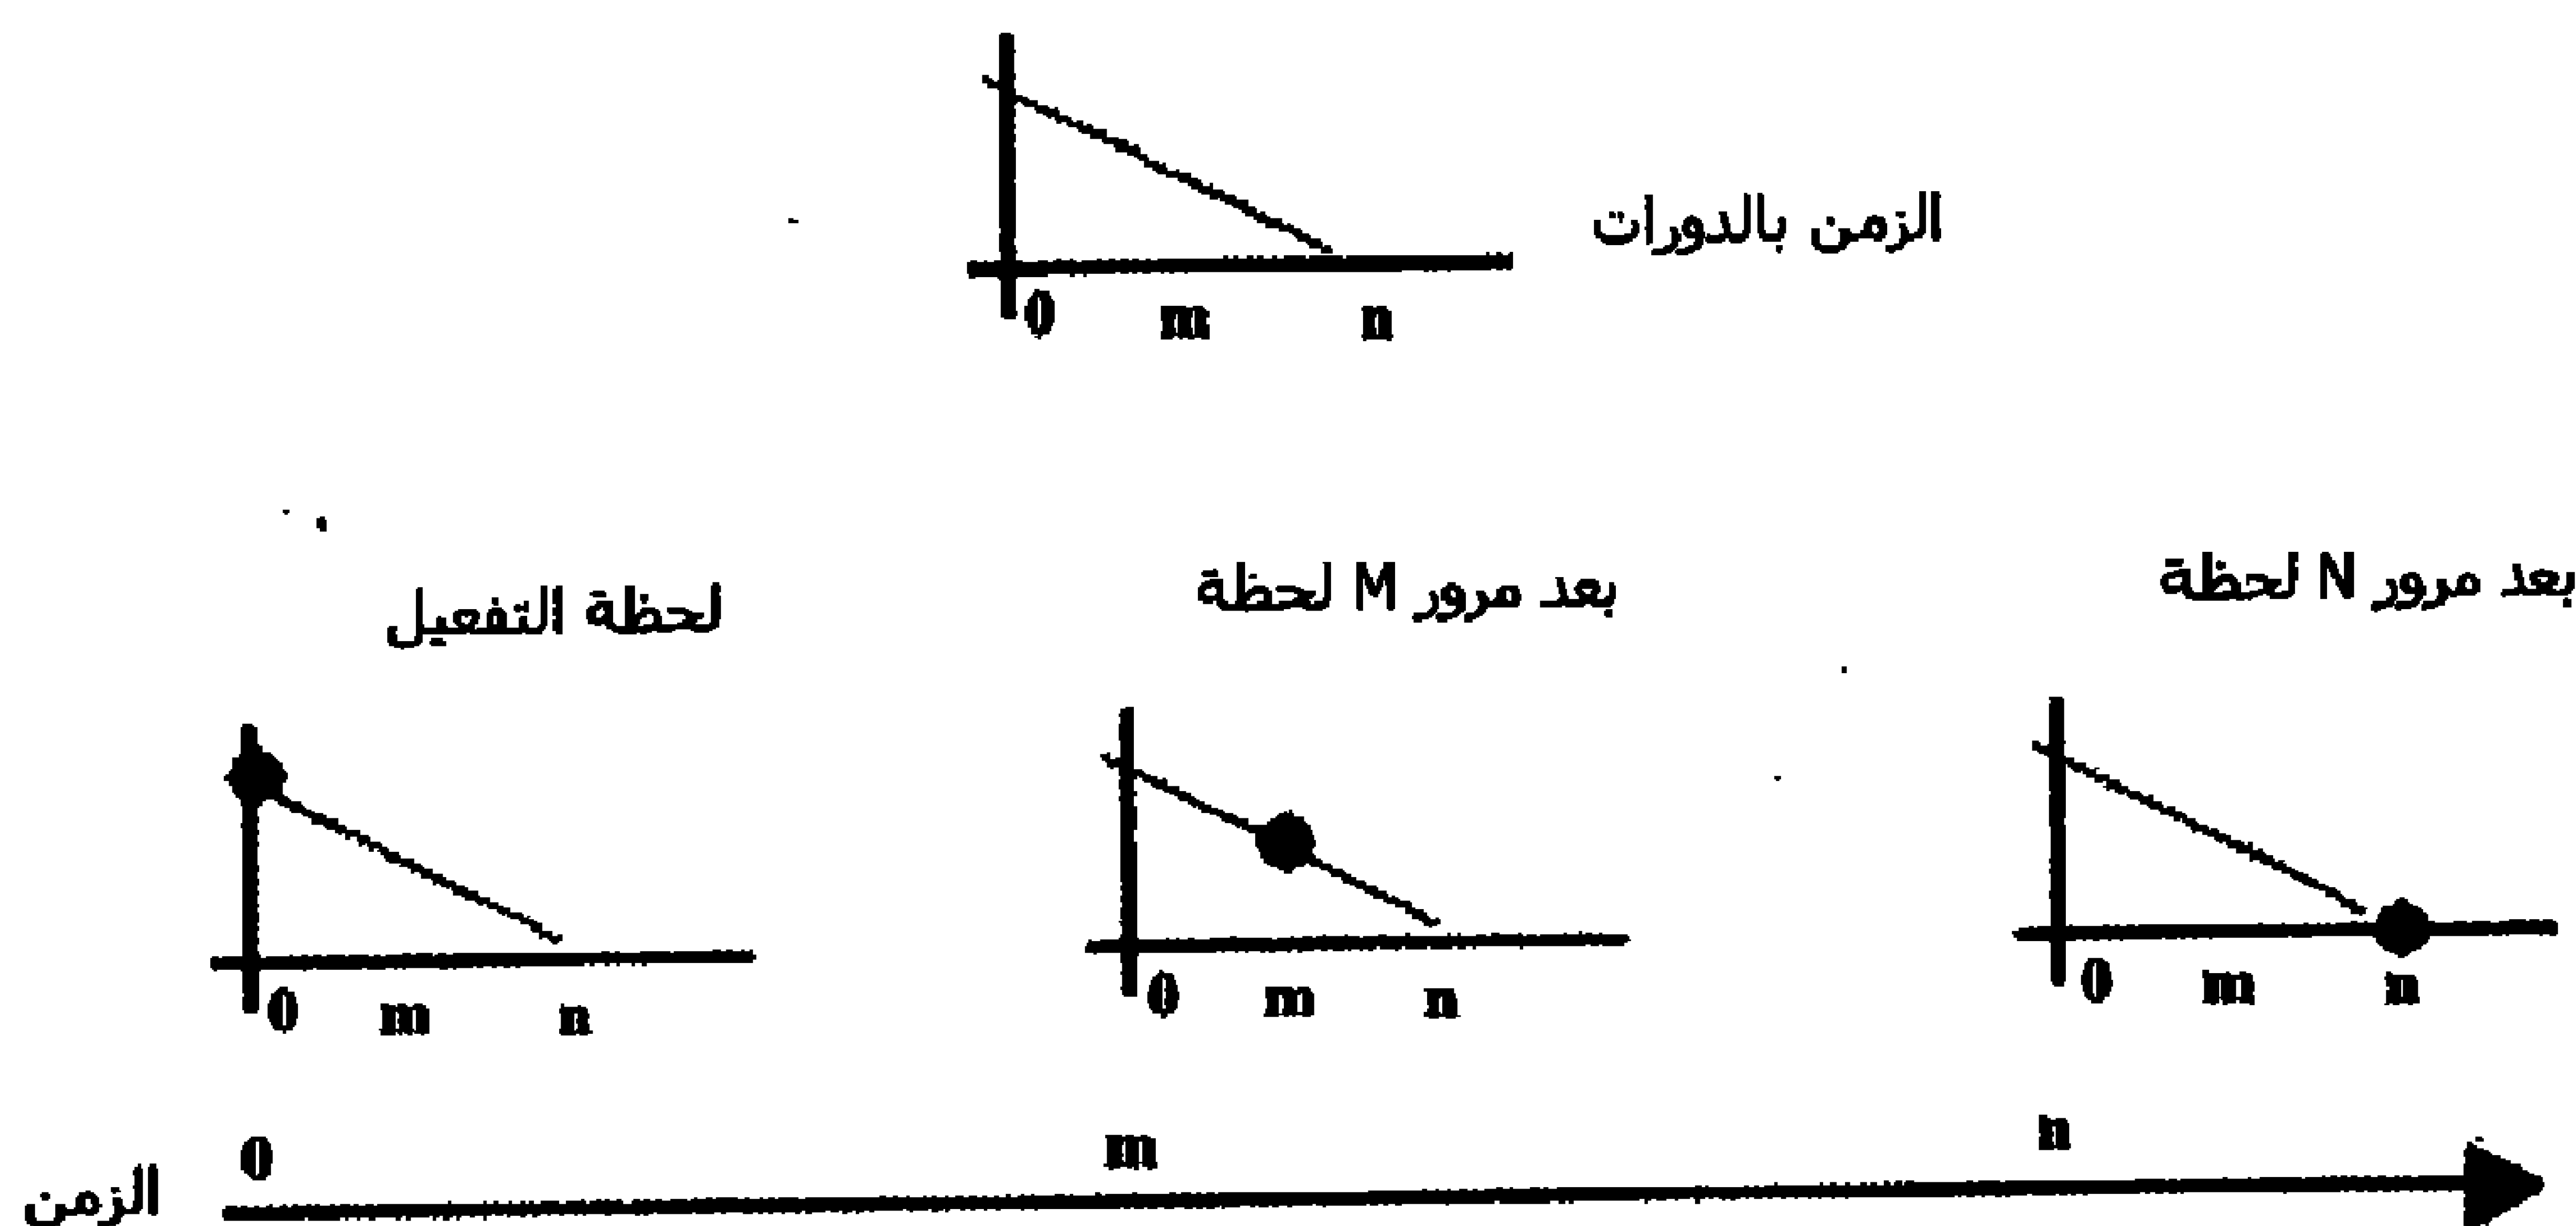
يغير نموذج ANN هذا مفهوم الاتصالات بين العصبونات، الذي يبدل من كونه رقماً (قيمة عددية فقط)، لُيمثل بوساطة تابع (خط بميل سالب يُوصف بقيمة الميل).

الآن، يجب أن يتم شرح تابع العصبون كتابع زمني. أي أن تفعيل العصبون يصل إلى سلسلة مدخلات خلال لحظة زمنية. وهذا لا يؤثر فقط في عصبونات الخرج في تلك اللحظة، بل يؤثر في العصبونات اللاحقة خلال n لحظة أيضاً (الشكل 12). تتعلق قيمة n بميل ذلك الاتصال.

تُعطى معادلة الخط الذي يحاكي التفعيل الموهن زنياً للعصبونات الطبيعية كالآتي:

$$Y = mx + b \qquad (1)$$

***الشكل (12)** الأداء الوظيفي لتفعيل العصبون*



في هذه المعادلة: تمثل y قيمة خرج العصبون المُستقبلة من قبل العصبونات اللاحقة، ويمثل الحرف b خرج تابع تفعيل العصبون، ويمثل الحرف X الزمن من لحظة التفعيل، أما m فهي ميل الخط

الذي هو - كما ذكرنا - ذو قيمة سالبة دائماً. في اللحظة التي يحدث عندها التفعيل يكون الزمن مساوٍ للصفر والخرج مساوٍ لـــ y = b، ثم يخفف الخرج بالاعتماد على الميل حتى يصل إلى الصفر خلال زمن مقداره x = t. عندما تُحدد البنية الهندسية الجديدة لتطبيق هذا النوع من ANN لحل المشاكل الحقيقية، فمن الضروري وضع خوارزمية تدريب بحيث تضبط الأوزان، وفي حالتنا تضبط ميول ANN. إن خوارزميات التعليم المستخدمة حتى الآن لهذا النوع الجديد من PE ليست صالحة، لأننا نحتاج لحساب ميول الخطوط لكل PE. لقد استخدمت GA لتدريب هذا النوع من ANN.

الحصول على ميول التفعيل

إن الخطوة الأولى لاستخدام GA هي ترميز كافة الحلول الممكنة كمصفوفة ذات n عنصر أو مورثة، بحيث تمثل حلاً ممكناً واحداً يمثل سلسلة فردية من المجتمع. في هذه الحالات، تُجمع ANN كمصفوفة ميول أو أوزان (ANN تكرارية أو لا تكرارية) من الطبقة الابتدائية إلى طبقة الخرج، بالإضافة لذلك، يجب أن يُجمع ليس فقط فيما إذا كانت ANN تكرارية، بل أيضاً جميع البارامترات العامة لـــ PE كقيمة الوزن الحدية، وقيمة الميل الحدية، ونوع تابع التفعيل (خطي، عتبي، أسي، وظلّي ذو قطع زائد)، كما تُجمع قيم RANN كالتدريب المستمر أو التدريب في أدوار، وعدد تكرارات ANN قبل تجميع الخرج. ما إن تُصمم السلاسل الفردية، حتى يشتمل الطور اللاحق على توليد المجتمع العشوائي، حيث ستُطبق المعاملات الوراثية.

النتائج

تم في هذا القسم تنظيم النتائج التجريبية المنجزة في ثلاثة أقسام. أولاً، ستُنفذ عدة اختبارات للتحقق من أن هذه الـــ ANN التي تستخدم التفعيلات الموهنة زمنياً قادرة على التدريب، وقادرة أيضاً على توليد المعلومات المتعلقة بمجموعات التدريب والاختبار. وما أن يُحقق هذا الغرض، فإن المرحلة الثانية ستتضمن تنفيذ عدة اختيارات يدوية لضبط البنية الهندسية من أجل مقارنتها خلال المرحلة الثالثة بواسطة الضبط الآلي المقدم من قبل منظومة متعددة المستويات لتطوير ANNs.

تم استخدام سلسلتين زمنيتين كلاسيكيتين في المجال الإحصائي للتحقق من صلاحية المنظومة المقترحة: عدد البقع الشمسية المكتشفة في العام في الفترة ما بين 1701 و1987؛ وإنتاج الولايات الأمريكية للتبغ في الفترة ما بين عام 1871 وحتى 1984 م. تمتلك السلسلة الأولى 287 قيمة، وأُبقي على القيم الخمس الأخيرة من أجل طول اختبار ANN. أما السلسلة الثانية فتتضمن 114 حالة، وتُستخدم القيم الثمانية الأخيرة من أجل طور الاختبار.

سوف يستخدم زمن التدريب لإعطاء فكرة عن أداء كل اختبار نسبةً للاختبارات الأخرى. لا يوجد دلالة واضحة في كل اختبار بشكل مجرد، وذلك لأنه يتعلق بإمكانيات الحاسوب المستخدم لتنفيذ الاختبار. في حالتنا، الحاسوب المستخدم هو + AMDXP 1600 مع ذاكرة RAM 512 DDP ميغا بايت وبسرعة 266 ميغا هرتز. كما يمكن استخلاصه من الجداول السابقة في سائل التنبؤ للسلسلة الزمنية، فإن استخدام أو التوهينات الزمنية في PE تحسن تدريب ANN بشكل ملحوظ، وبالتالي يحسن أيضاً مستوى الخطأ الناتج بناءً على ذلك.

يُقارن مستوي الملاءمة لـــ RANN الأفضل المكتوب بلون غامق في (الجدول 1 و2) مع التنبؤات المكتسبة بوساطة نماذج ARIMA. وكما يلاحظ من (الجداول 3 و4)، فإن التنبؤات المكتسبة بواسطة الـــ RANN تمثل مستويات دقة أعلى أو مشابهة لتنبؤات نماذج ARIMA المستخدمة، في هذه الحالة هي (ARIMA (2, 0, 0 من أجل البقع الشمسية، و(ARIMA (0, 1, 1 من أجل إنتاج التبغ (Andrews & Herzberg, 1985). الخطأ المئوي هو الفرق المضبوط بمجال كل متغير بين القيمة المتوقعة والقيمة الحقيقية. على الرغم من أن تنبؤ قيمة السلسلة لا يصادف تحسيناً كبيراً بحيث يمكن أن تدعم استخدام RANN في تنبؤ السلسلة الزمنية، فإن صلاحية استخدامها – كما هو مبين في جداول النتائج – تسمح بتقارب هذه المشكلة مع معرفة إحصائية طفيفة.

الجدول (1) بارامترات ANN من أجل سلسلة البقع الشمسية

زمن التفعيل	دورة	تابع التفعيل	PE	زمن التدريب	MSE
0.5	10	أسي	4	49' 15"	0.0165
0.01	10	أسي	4	49' 30"	0.0180
0.01	1	سيمغويد	4	7' 15"	0.0373
0.01	1	أسي	7	11' 30"	0.0400

الجدول (2) بارامترات ANN من أجل سلسلة تبغ

زمن التفعيل	دورة	تابع التفعيل	PE	زمن التدريب	MSE
0.5	10	أسي	4	21' 30"	0.0136
0.01	10	أسي	4	21' 15"	0.0206
0.01	1	سيمغويد	4	5' 15"	0.0487
0.01	1	أسي	7	5' 00"	0.0259

الجدول (3) مقارنة القيم الحقيقية للبقع الشمسية بالنسبة للأعوام من 1979 وحتى 1986 مع أفضل تنبؤ ANN ونموذج ARIMA

حقيقي	ANN	خطأ ANN %	ARIMA	خطأ ARIMA%
154.6	165.88	5.93	124.7	15.73
140.4	146.76	3.34	83.33	30.03
115.9	129.62	7.22	52.71	33.25
66.6	95.44	15.17	28.21	20.20
45.9	56.59	5.62	16.09	15.68
17.9	41.47	12.40	12.68	2.74
13.4	26.55	6.92	20.99	3.99
29.3	24.86	2.33	45.24	8.39

الجدول (4) مقارنة القيم الحقيقية لإنتاج التبغ المتعلقة بفترة السنوات ما بين 1980 و1984 مع أفضل تنبؤ ANN ونموذج ARIMA

حقيقي	ANN	خطأ ANN %	ARIMA	خطأ ARIMA%
1785.89	1668.13	4.99	1716.16	2.94
2063.89	1787.37	11.77	1740.14	13.77
1994.04	2003.76	0.38	1764.30	9.81
1428.90	1996.31	24.18	1788.78	15.35
1727.99	1590.33	5.84	1813.61	3.67

التفعيلات الموهنة زمنياً

لقد استخدمت استراتيجية الصفوة، حيث أن السلسلة الفردية الأفضل في المجتمع لا تُعوض بالطفرة. بالنسبة لبارامترات الأداء، فخلال كل دورة لـ GA يشمل التصالب على ثلاثة أزواج، وتؤثر الطفرة في أربعة سلاسل فردية. عدد السلاسل الفردية في المجتمع هو 200. من أجل تحقيق بارامترات الأداء هذه لـ GA، تم اختبار خيارات مختلفة متعلقة بنماذج اختيار السلسلة الفردية من أجل التصالب ومتعلقة بمعدلات التصالب والطفرة. وقد تم اعتماد الخيارات التالية بشكل خاص نتيجةً لسرعة تقارب GA. تظهر الجداول التالية بارامترات ANN الأربعة مطورة للتنبؤ بقيم كل مسألة. استخدمت أولى الشبكتين التوهين الزمني. يبين حقل "زمن التفعيل" أي دورة تقييم ANN تمثيل المتغير X في المعادلة (1) (الزمن غير مستنفذ في كل دورة).

يمثل الحقل "دورة" عدد الدورات المتوقعة من لحظة إدخال قيمة الدخل حتى التمكن من تجميع قيمة الخرج. إذا كانت (الدورة = 1) فلا تؤخذ عملية التكرار بالحسبان. يدل عمود PE على عدد عصبونات الطبقة الخفية. تكون قيمة الحد العلوي للأوزان في الـــ ANN الأربعة هي 20، وعدد دورات التدريب هو 14.000. يمثل زمن التدريب ومتوسط مربع الخطأ الناتج (MSE) معدل النتائج التي تم الحصول عليها بعد أربع محاولات مختلفة باستخدام نفس تشكيلة GA، ولكن مع مجتمعات ابتدائية مختلفة لـــ ANNs.

الحصول على البنية الهندسية المثالية

عندما يتم اختبار أداء الدقة للتفعيلات الزمنية، ستظهر النتائج التي تم الحصول عليها بنظام الضبط الآلي للبنى الهندسية. وتكون نتيجة هذا النظام شبكة مثالية بما يتعلق ليس فقط بعدد العصبونات الخفية ومصفوفة الاتصالات، بل وأيضاً بتوابع التفعيل لكل عصبون. أولاً، سيكون الضبط اليدوي هو المقصود قبل كل شيء وسيشمل على اختيار عدد PE كرقم واحد من المجموعة التالية {2, 4, 6} وأحد توابع التفعيل الآتية {خطي، سيغمويد، ظلي ذو قطع زائد}. ثم تُختبر بارامترات كل توليفة وتُدرب البنية الهندسية الناتجة بوساطة نموذج تدريب مبني على GA. تشكيلة GA هذه مبينة في (الجدول 5).

الجدول (5) بارامترات GA لمستوي التدريب

المجتمع	معدل التصالب	معدل الطفرة	نوع التصالب	تعويض (استبدال)	تنفيذ
100	5 %	1 %	أحادية النقطة	السلسلة الفردية الأسوأ	25.000 تكرار

يبين (الجدول 6) أفضل نتائج الضبط اليدوي الناتجة عن توليفة البارامترات لكل سلسلة زمنية.

الجدول (6) بارامترات ANN التي تعطي أفضل النتائج للضبط اليدوي

السلسلة	PE	تابع التفعيل	MSE	متوسط الخطأ (ME)	زمن التدريب الكلي
البقع الشمسية	4	خطي	0.00711	0.06208	3 دقائق 51 ثانية
التبغ	6	سيغمويد	0.00693	0.05995	14 دقيقة و1 ثانية

المدة الزمنية الكاملة للاختبار المنفذ من أجل التحقق السلوكي لكل توليفة من توليفات السلسلة الزمنية للبقع الشمسية كانت مساوية لـــ 6.642 ثانية (1 ساعة و50 دقيقة و42 ثانية).

أما من أجل سلسلة التبغ فلزم مدة مقدارها 153 ثانية (2 دقيقة و33 ثانية) لاختيار كافة التوليفات. حالما تُنشأ البنية الهندسية الأفضل يدوياً، يتم توليد بنية هندسية جديدة بوساطة الإجراء المذكور سابقاً من أجل مقارنة النتائج الحاصلة. وتشمل هذه البنية الهندسية على 200 تكرار لخوارزمية مستوي التصميم الوراثية خلال كل اختبار. على الرغم من أن عدد التكرارات قليل، فإنه من المتوقع أن تظهر النتائج إمكانية المنظومة المنفذة. أما بقية بارامترات خوارزمية مستوي التصميم الوراثية فهي مبينة في (الجدول 7).

يتم الحصول على قيمة الملائمة لكل بنية هندسية باستخدام نموذج تدريب ANN عن طريق GA كتابع تقييم. ستنفذ GA 50 دورة من أجل كل بنية هندسية، كي يكون زمن التدريب مقيداً خلال تقييم كل سلسلة فردية.

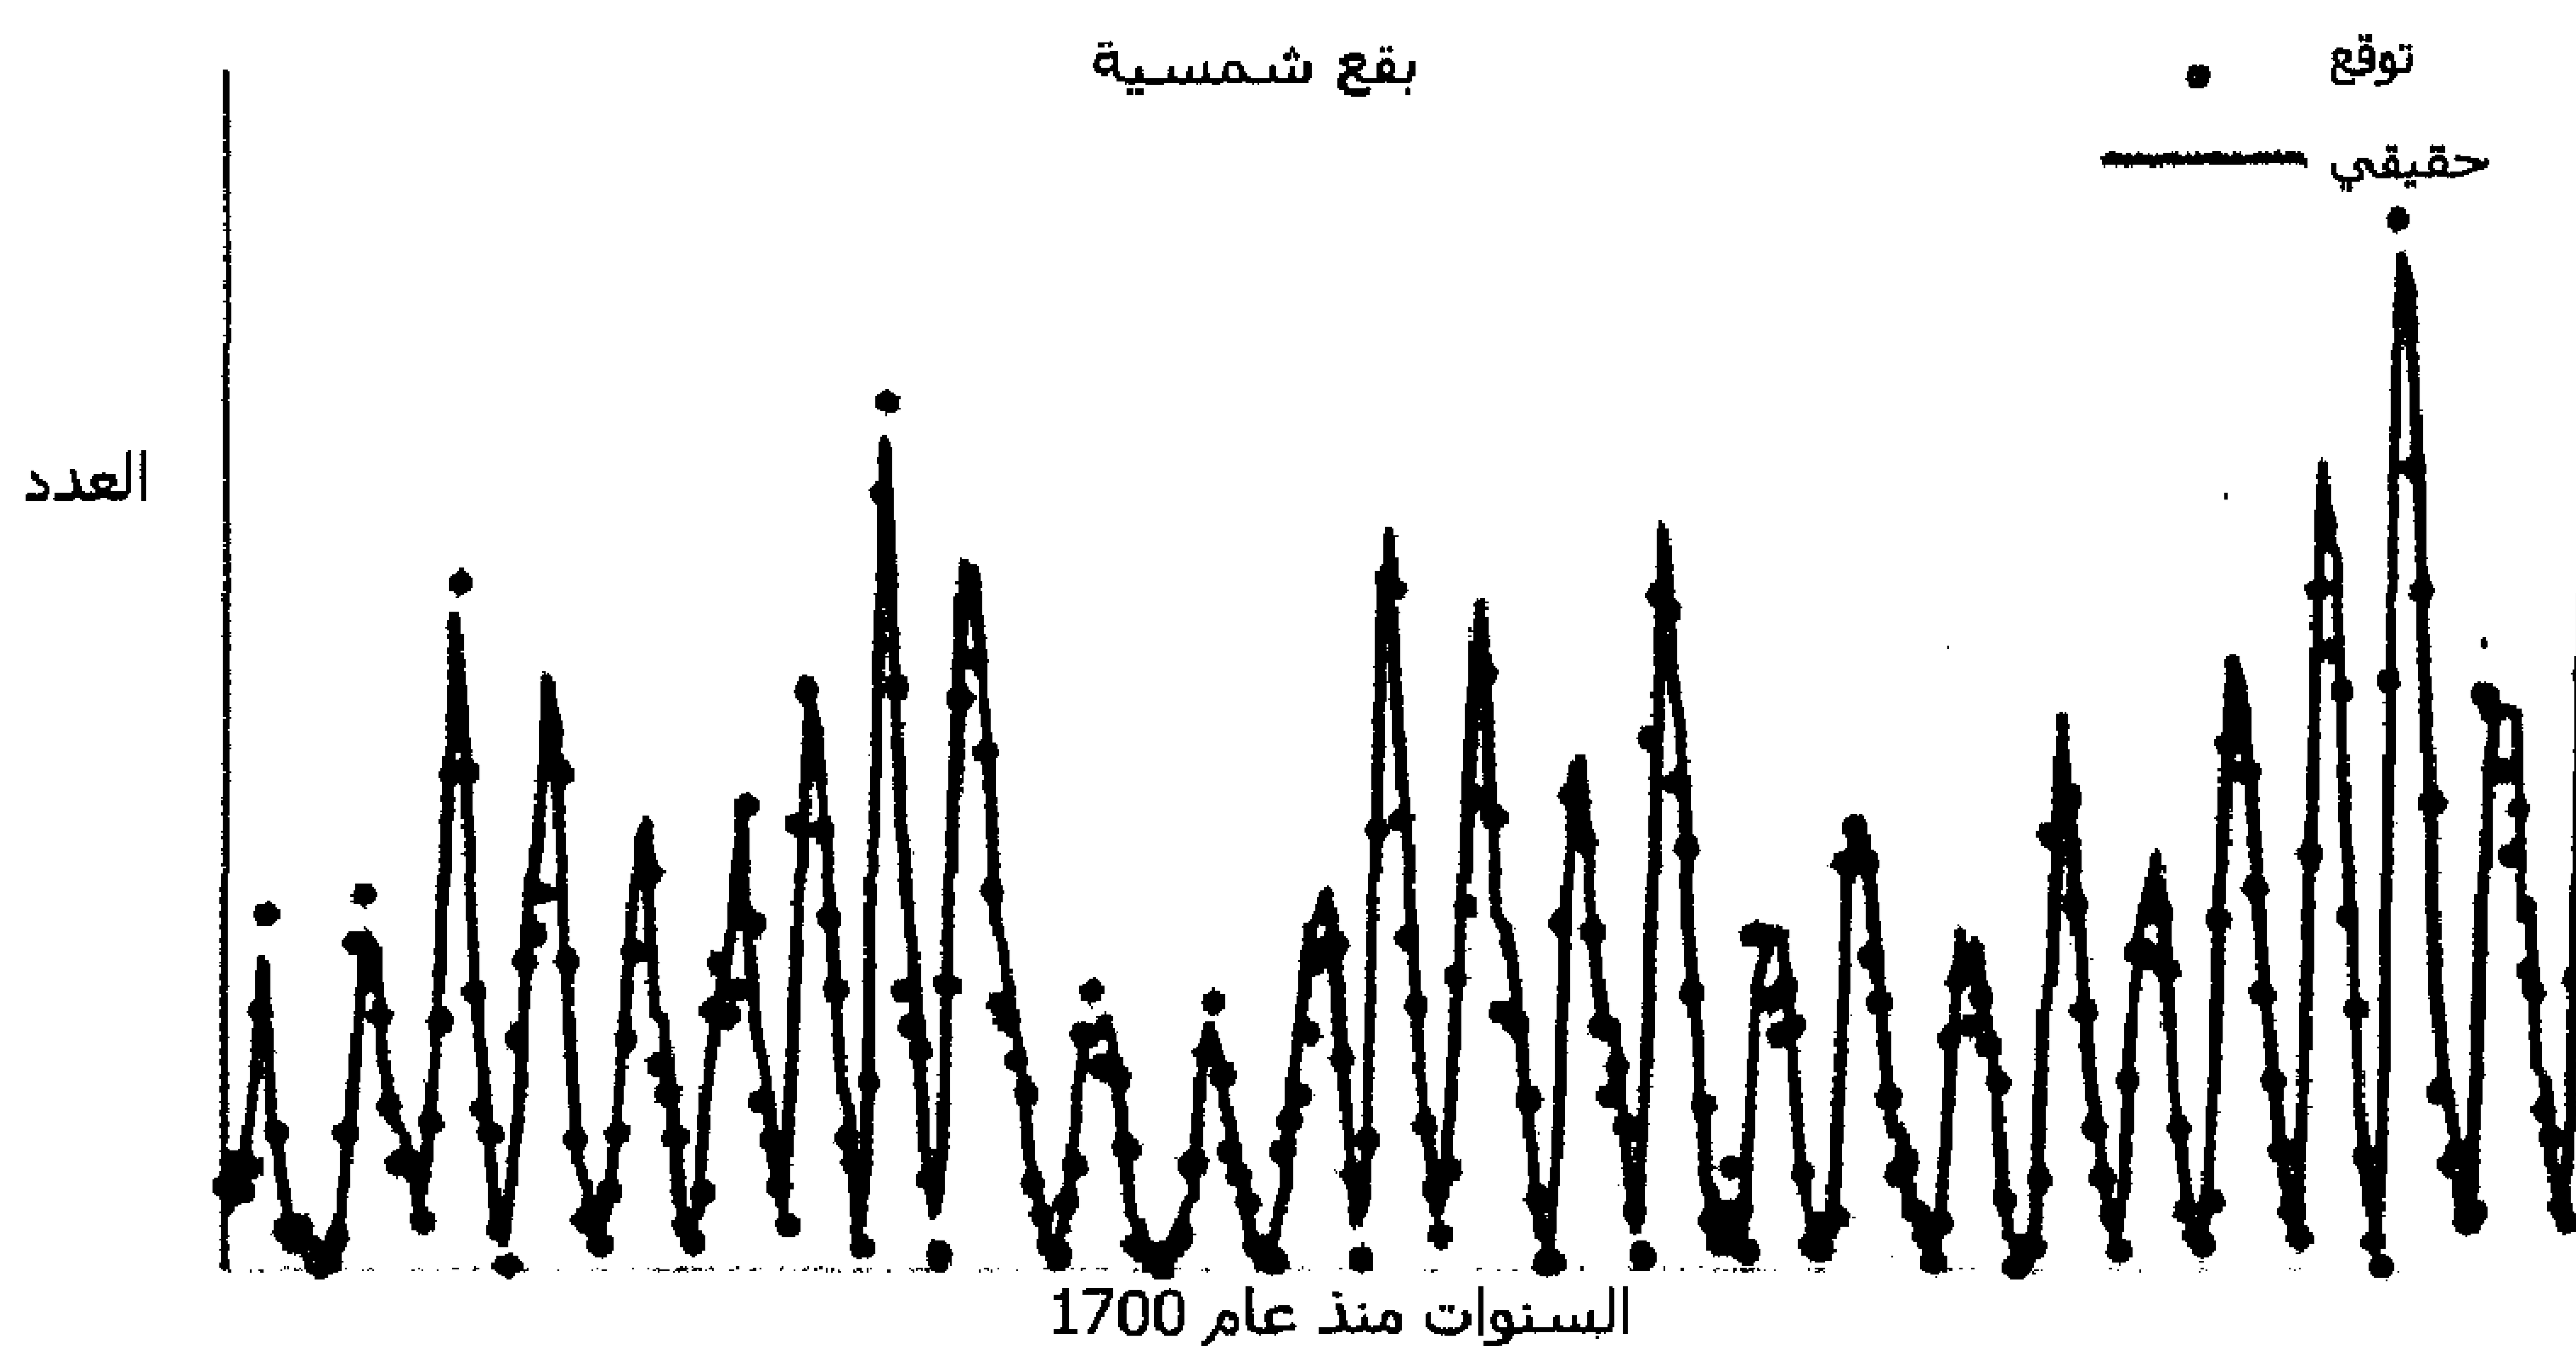
الجدول (7) بارامترات خوارزمية مستوي التصميم الوراثية

المجتمع	معدل التصالب	معدل الطفرة	نوع التصالب	استبدال (تعويض)
100	5 %	1 %	أحادي النقطة	السلسلة الفردية الأسوأ

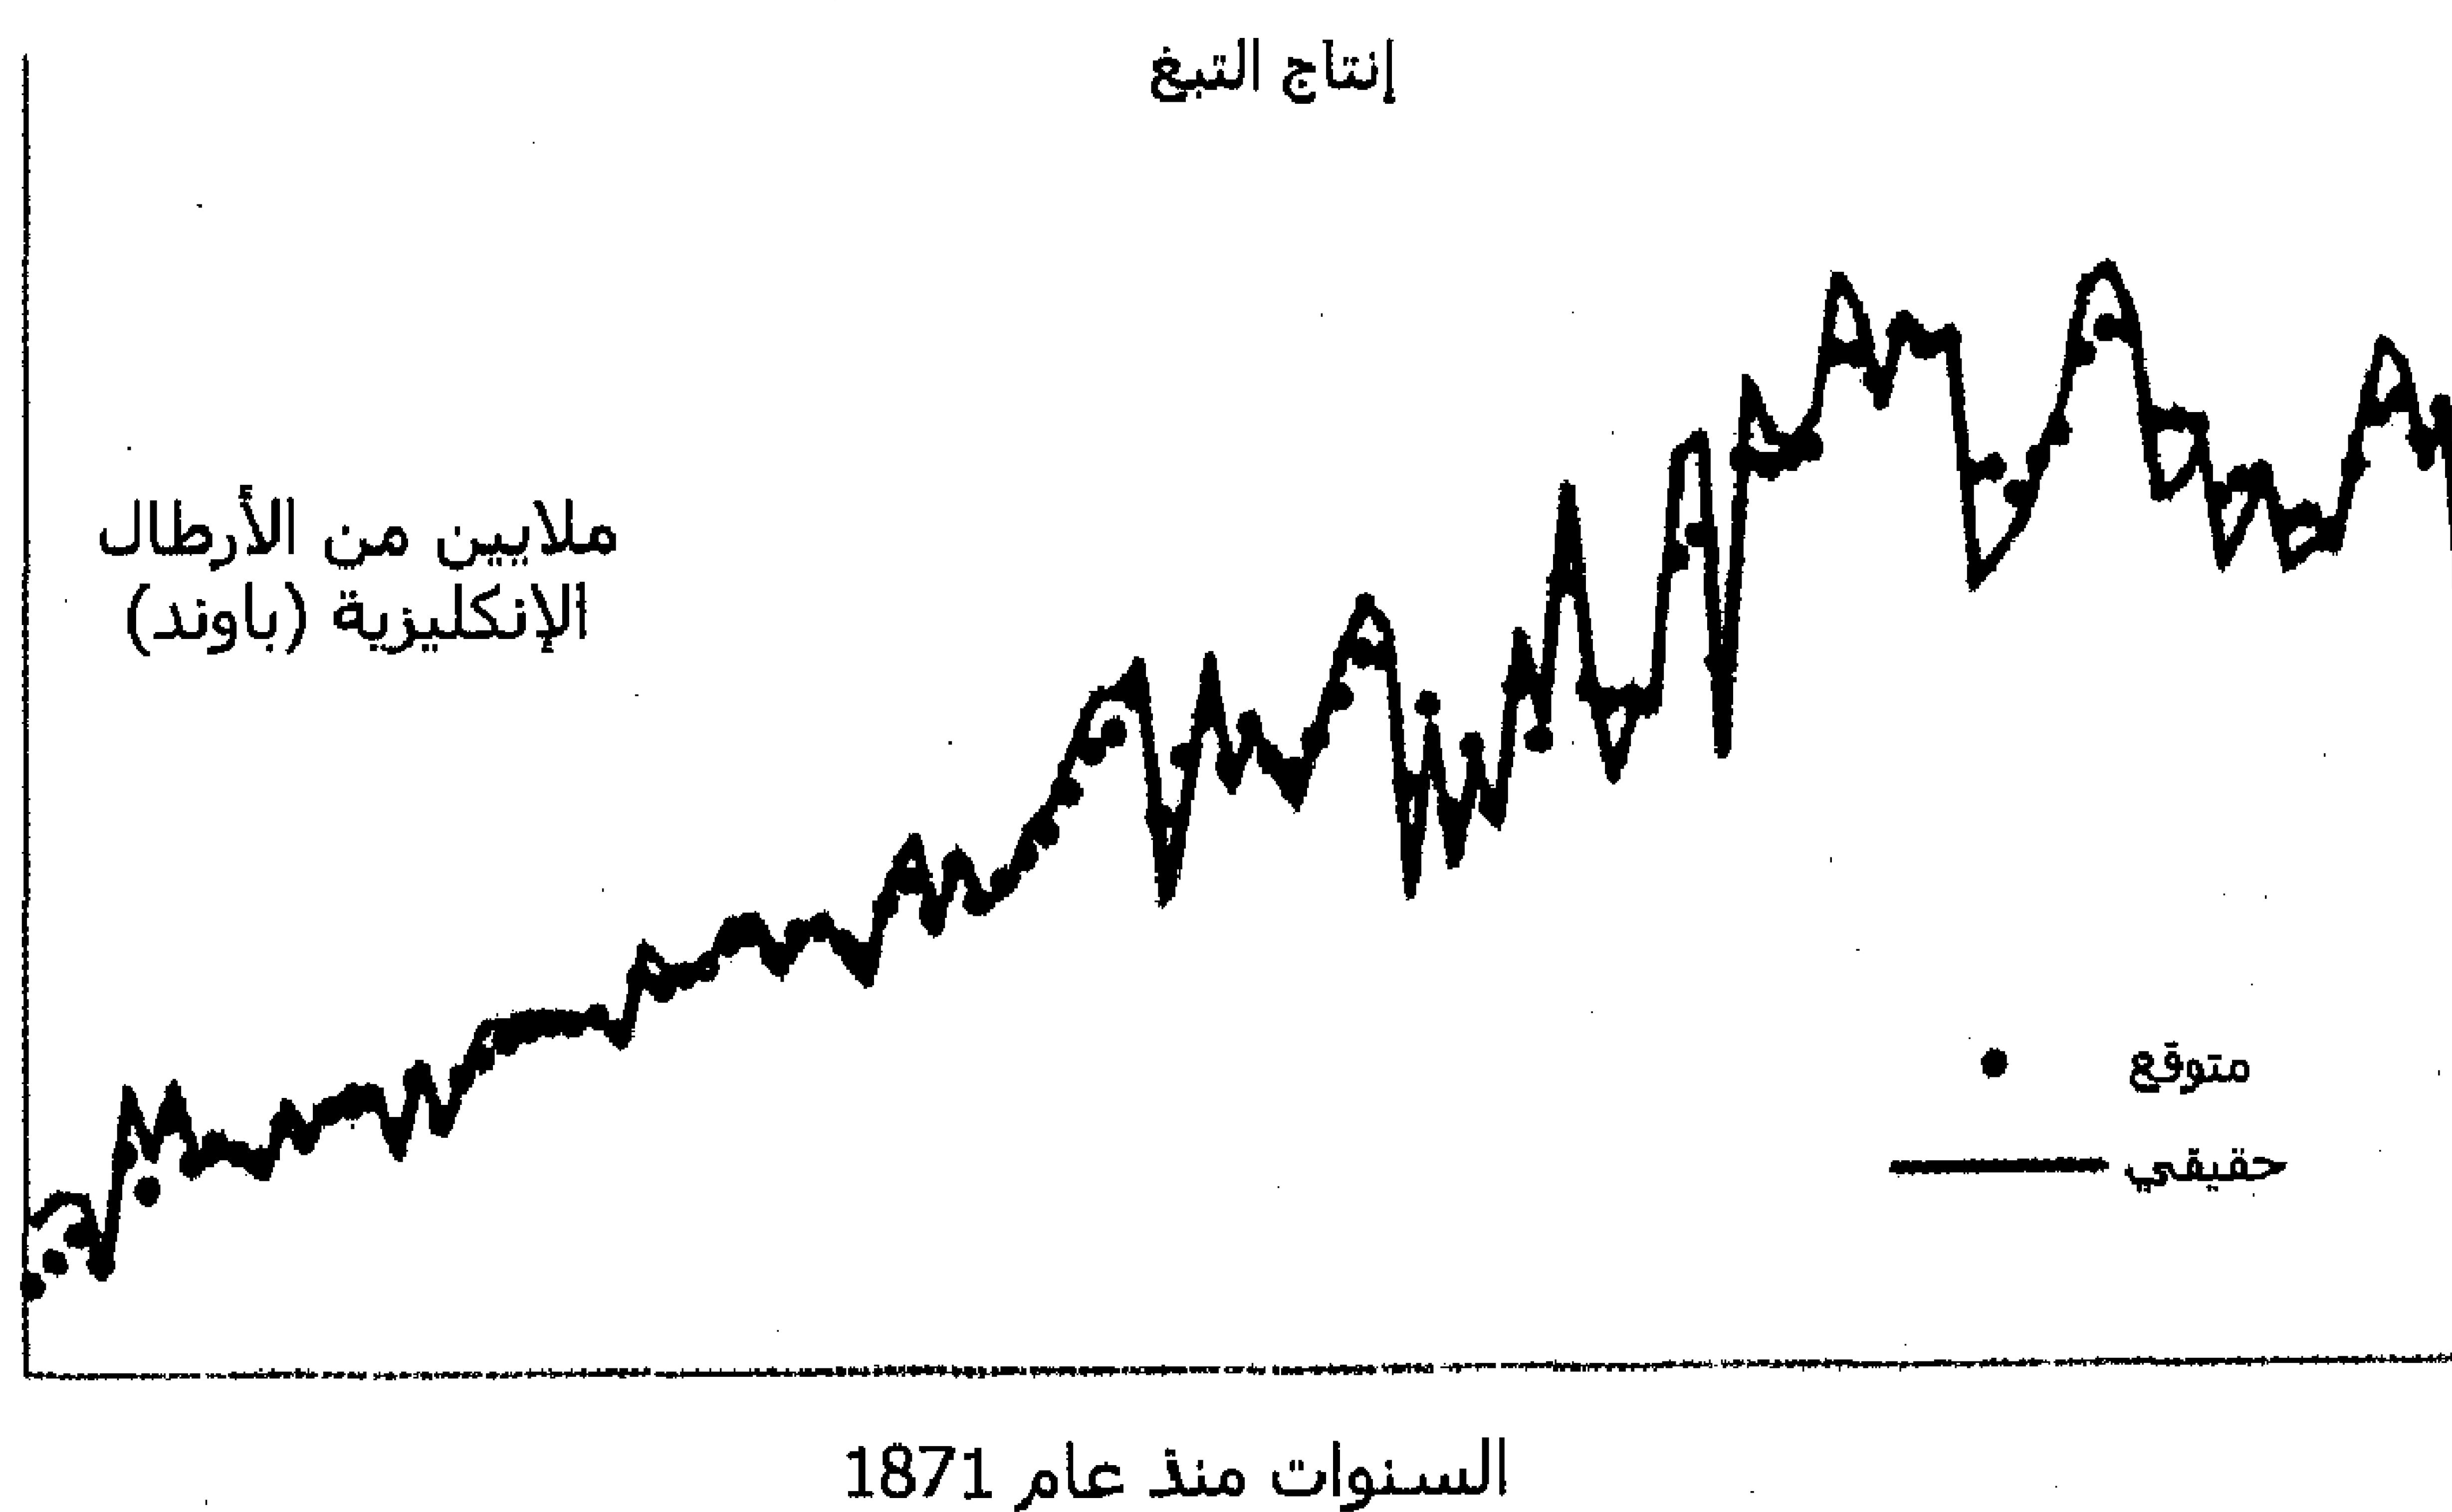
من غير الملائم تنفيذ GA خلال عدد كبير من الدورات، لأن ذلك سيؤدي إلى تحقيق قيمة دالة على جودة البنية الهندسية، وبالتالي، يجب أن يكون هذا العدد هو العدد الأقل الذي يمكن أن يسمح بتقييم ANN خلال فترة زمنية مقبولة. على أنه، إذا كانت هذه القيمة صغيرة جداً فيمكن ألا تبدأ ANN بعملية التقارب، وبالتالي، يمكن ألا تُحقق القيمة الدالة على الجودة. كانت قيمة التكرار الابتدائية خلال الاختبار المنفذ مساوية لـــ 100، غير أنه تم إثبات بأنها غير كافية، وذلك لأنه في أغلب الحالات لا تحدث تحسينات باستخدام هذا العدد من الدورات. تمت زيادة هذه القيمة بشكل متتالٍ بخطوة مقدارها 100 ليصبح العدد الكلي للتكرارات لكل ANN مساوياً لـــ 500. تسمح هذه القيمة ببدء عملية التقارب لـــ ANNs. ومن الواضح بأنه من الضروري ضبط هذا البارامتر كي يتم تكيّفه مع المشكلة المُعالجة في كل حالة. بعد 200 دورة تنفيذ لـــ GA من أجل أتمتة تصميم البنية الهندسية، ترمز السلسلة الفردية الأفضل البنية الهندسية الأحسن ملاءمةً. توافق قيمة ملاءمتها الخطأ المرتكب بواسطة ANN مع تلك البنية الهندسية المدربة خلال الـــ 500 تكرار المذكورة للتو. تم إثبات صلاحية البنية الهندسية الأفضل الناتجة من خلال تدريب منفذ يشمل على 25.000 تكرار، وذلك بطريقة تمكّن من مقارنة النتائج مباشرةً مع تلك المنجزة للتو.

سلسلة البقع الشمسية

الشكل (13) *سلسلة البقع الشمسية مقابل القيم المتوقعة لـ RANN*



الشكل (14) *سلسلة التبغ مقابل القيم المتوقعة لـ RANN*



تظهر بارامترات أفضل حل منجز في (الجدول 8)

الجدول (8) بارامترات ونتائج ANN الأفضل من أجل تنبؤ سلسلة البقع الشمسية

زمن التدريب	PE	الاتصالات	توابع التفعيل	MSE	ME
1:23:10	6	26	LLSLLH	0.00862	0.07230

L – خطي، S – سيغموند، H – عتبي.

سلسلة التبغ

كما تظهر البارامترات المحددة لـــ RANN المنجزة لأفضل النتائج في (الجدول 9)

الجدول (9) بارامترات ونتائج ANN الأفضل من أجل تنبؤ سلسلة التبغ

زمن التدريب	PE	الاتصالات	توابع التفعيل	MSE	ME
35:55	5	14	LL LL H	0.00841	0.06817

L – خطي H – عتبي، أول ملاحظة يمكن الاشارة إليها (الجدول 10)، هي أن الأخطاء الناتجة لكلا السلسلتين الزمنيتين أعلى بقليل، من النهايات الصغرى المنجزة بالتشكيلة اليدوية ولكنها قابلة للمقارنة معها. ويكمن سبب ذلك في مدة التنفيذ – 200 دورة – التي نفذت خلالها الأتمتة، لأن هذه المدة قصيرة جداً لتتمكن GA أن تحل بشكل كامل هذا النوع من المشاكل التي تصادفنا. بالتالي، ومع استمرار عدم وجود تحسن ملحوظ للخطأ. فإن GA لملاءمة البنية الهندسية قد خفضت زمن عملية التشكيل اليدوي، الذي كان مساوياً لـــ 1 ساعة و45 دقيقة لسلسلة البقع الشمسية، و45 دقيقة لسلسلة التبغ. خلال زمن تنفيذ GA هذه، تم تنفيذ مهام إضافية مختلفة عن تلك المنفذة في التشكيل اليدوي، كالاختبار مع عدد عصبونات أكبر (بين 1 و6)، واتصال "تشذيب"، والاختيار الآلي لتوابع تفعيل PE.

الجدول (10) مقارنة بين التشكيل اليدوي وتشكيل GA

السلسلة	البارامتر	ضبط بارامترات GA	ضبط البنية الهندسية	الفرق
البقع الشمسية	الزمن	6.642 ثانية	4.990 ثانية	% -24.8
	MSE	0.0077	0.0086	% + 11.7
إنتاج التبغ	الزمن	3153 ثانية	2.035 ثانية	% - 35.5
	MSE	0.0071	0.0084	% 18.3

الخلاصات

يجب الإشارة أولاً، إلى أن العملية التي تتضمن تصميم وتدريب ANN تكرارية كانت أم لا، تُنفذ باستخدام تقنيات EC. في تلك الطريقة، يقوم المصمم بتعريف مهمة اختبار كل توليفة من التوليفات الممكنة للبنية الهندسية كخوارزميات تعليم مختلفة.

فيما يتعلق بتعديل البنية الهندسية الكلاسيكية لـ ANN باستخدام التفعيلات الموهنة زمنياً. وبعد النتائج التي تم الحصول عليها (الجدول 3 ,4)، يمكن القول بأن مستوى الخطأ الناتج قد تحسّن بشكل ملحوظ. وبالتالي، يبدو بأن الغرض من مساعدة ثبات حالات التفعيل الداخلية لـ ANN قد أنجز أخيراً، وهو يحسن مرونة تكيّف ANN عند حل مثل هذه الأنواع من المشاكل.

كما يظهر الأداء الجيد للتفعيلات الزمنية أيضاً إمكانية هذه الطريقة المعتمدة على GA لكي تضم بسهولة الميزات الجديدة لأداء ليس فقط PE أو الطبقات، بل والاتصالات أيضاً، بحيث يمكن أن تصبح وظائفها قريبة من مثيلاتها في الشبكة العصبونية البيولوجية. فتحت المقالة إمكانيات جديدة من أجل تحسين أداء المنظومات الربطية (الاتصالية)، وأيضاً من أجل اختبار نظريات جديدة في النماذج الحاسوبية لـ ANNs.

بقدر ما هو يولى التصميم الآلي البنية الهندسية لـ ANN من الاهتمام، فإن المنظور الشمولي المقدم من قبل المنظومة يُقرّب كل الجوانب المختلفة لتطوير ANN. تحث هذه المشكلة - التي لا يوجد لها حل رياضي داعم حتى الآن - على تطوير الشبكات غير المثالية نتيجةً للمقدار الكبير للزمن اللازم لاختبار كافة البنى الهندسية الممكنة للشبكة. تستخدم المنظومة المقترحة GA لضبط ليس فقط عدد العصبونات والطبقات، بل وأيضاً لإنجاز تشذيب الاتصالات غير الضرورية، ولاختيار توابع التفعيل لكل عصبون. هذا النوع من المنظومات - بالإضافة إلى أنه يحافظ على زمن التنفيذ العام - فإنه يسمح أيضاً بإبعاد المصمم نفسه عن المهمة المطولة والمملة لاختيار البنية الهندسية، بحيث أنها تصبح مرحلة انتقالية لمهام تطوير ANN. خلال عملية الاختبار المنفذ وبعيداً عن الأتمتة المتضمنة تطوير ANNs، فإن المنظومة تحقق أيضاً نتائج قابلة للمقارنة مع تلك التي تم الحصول عليها باستخدام نموذج ARIMA للسلسلة الزمنية.

المراجع

Andrews, P.E., & Herzberg, A.M. (1985). The data: A collection of problems from statistics. Springer-Verlag.

Bäck, T. (1996). Evolutionary algorithms in theory and practice. Oxford: Oxford University Press.

Bethke, A.D. (1981). Genetic algorithms and function optimizers. Unpublished doctoral dissertation. University of Michigan.

Box, G.E.P.,&Jenkins, G.M. (1976). Time series analysis forecasting and control. San Francisco: Holden Day.

Bramlette, M.F. (1991). Initialization, mutation and selection methods in genetic algorithms for function optimization. In R.K. Belew & L.B. Booker (Eds.), Proceedings of the Fourth International Conference on Genetic Algorithms (pp. 100-107). San Francisco: Morgan Kaufmann.

Cybenko, G. (1989). Approximation by superposition of sigmoidal function. Mathematics of Control, Signals and Systems, 2, 303-314.

Fogel, D.B., Fogel, L.J., & Porto, V.W. (1990). Evolving neural networks. Biological Cybernetics, 63, 487-493.

Freeman, J., & Skapura, D.M. (1993). Neural networks. Boston: Addison-Wesley.

Fritzke, B. (1995). A growing neural gas network learns topologies. In G. Tesauro, D.S. Touretzky, & T.K.Leen (Eds.), Advances in neural information processing systems (vol. 7, pp. 625-632). Cambridge, MA: MIT Press.

Gomm, J.B., Weerashinghe, M., & Willians, D. (1998). Pruning and extractions of qualitative fault diagnosis rules from a neural network. Unpublished dissertation at Workshop on On-line Fault and supervision in the chemical process industries, Lyon,Prance.

Haykin,S. (1999). Neural networks, a comprehensive foundation. NJ: Prentice-Hall.

Holland, J.H. (1975). Adaptation in natural and artificial systems. Ann Arbor: The University of Michigan Press.

Lapedes, A., & Farber, R. (1988). How neural nets work. In D.Z Anderson (Eds.), Neural information processing systems (pp. 442-456). American Institute of Physics.

Martinetz, T.M., Berkovich, S.G., & Schulten, K.J. (1993). Neural-gas network for vector quantization and its application to time-series prediction. IEEE Transactions on Neural Networks, 4(4), 569.

Robbins, G.E., Hughes, J.C., Plumbley, M.D., Fallside, F., & Prager, R. (1993). Generation and adaptation of neural networks by evolutionary techniques (GANNET). Neural Computing and Applications, /(I), 22-30.

Setiono, R. (1997). A penalty function approach for pruning feedforward neural networks. Neural Computation, 9(1), 185-204.

Wei, W.S. (1990). Time series analysis. Univariate and multivariate methods. Boston: Addison Wesley.

Whitley, D., Starkweather, T., & Bogart, C. (1990). Genetic algorithms and neural networks. Connections and connectivity. Parallel. Computing, 14, 347-361.

Yao, X. (1992). A review of evolutionary artificial neural networks. Technical report Commonwealth Scientific and Industrial Research Organization.

Yee, P. (1992). Classification experiments involving backpreparation and radial basis function networks. Communications Research Laboratory. Report no. 249. McMaster University.

القسم 3

التنقيب عن البيانات

الفصل الخامس

الأنظمة العصبونية الذكية ذاتية التكيّف باستخدام تقنيات تطورية

ملخص

يصف هذا الفصل تقنيات معتمدة على GA من أجل بناء أنظمة عصبونية ذكية آلياً. يمكن أن تُستخدم هذه التقنيات لبناء وتدريب شبكات Perceptrons متعددة الطبقات بالبنية الهندسية الأبسط. تُصمم هذه الشبكات العصبونية عادةً باستخدام GAs مرمزة ثنائياً. يبين المؤلفون كيف تستخدم طريقة تصنيف البنى الهندسية الأساسية – التي تستخدم تصنيفاً معتمداً على الجبر – طول سلسلة أقصر، وتتفادى البنى الهندسية غير القانونية في فضاء البحث. تُدرب الشبكات باستخدام تصنيف عددي حقيقي.

يُقدم معامل التصالب المورفولوجي، ويُقارب مع تفاعلات تصالب هامة أخرى مرمزة بأعداد حقيقية. يكمن الغرض في فهم وإدراك أن توليفة (دمج) كافة هذه التقنيات تؤدي إلى نظام تطوري، يبني بشكل متكيف ذاتياً أنظمة عصبونية ذكية لحل مشكلة ما معطية كمجموعة أنماط التدريب. ولفعل ذلك، يُطبق النظام التطوري في اختبارات مخبرية على مشكلة عالم حقيقي: مثل تشخيص سرطان الثدي.

مقدمة

حالياً، يتعلق أحد مجالات الاهتمام الرئيسية في الذكاء الصنعي بتصميم الأنظمة ذاتية التكيّف، التي تكون قادرة على التحول لحل أنواع مختلفة من المسائل، أو على التكيّف للبيئة المتغيرة (konar, 2000). الشبكات Perceptrons متعددة الطبقات هي شبكات عصبونية أمامية الانتشار بطبقة دخل واحدة وطبقة خرج واحدة وعدة طبقات خفية. هذا النموذج قابل للتطبيق في الذكاء الصنعي لحل تنوع واسع من مشاكل العالم الحقيقي بفضل ميزاته للتعلّم بالأمثلة المعممة على بيانات غير مرئية وترشيح الضجيج وتصنيف الأنماط (الأشكال) (Principe, Euliano, Lefebvre, 2000).

على الرغم من محاسن هذه الأنظمة العصبونية الذكية، فإن أي بنية هندسية عصبونية لا تُنفذ إحدى المهام بدقة تكون عديمة الفائدة لحل مسألة أخرى. ومن الضروري أن تُصمم بنية هندسية جديدة من البداية ببناء الاتصالية الشبكية، وتحديد عدد الوحدات الخفية، ووضع الشروط في خوارزمية ضبط الأوزان. وهذا ليس بعمل بسيط حتى لأكثر الخبراء تجربةً بسبب حجم وتعقيد فضاء البحث حتى من أجل أفضل النماذج الشبكية المفهومة (Manrique, 2001). وفق هذه الشروط، لا يوجد شك حول بناء نظام ذكي ذاتي التكّيف معقد على شبكة عصبونية لحل أي مسألة مقدمة كمجموعة أنماط تدريب.

على أية حال، تم تحقيق نتائج ناجمة عن طريق تعريف تآزرات من خوارزميات تطورية وANNs، يمكن أن تُدمج لتصميم البنية الهندسية الداخلية للشبكة (Barrios, Manrique, Plaza, Rios, 2001). يمثل الأسلوب الذي تصنع فيه الشبكات العصبونية فضاء بحث مرمزاً لخطوةً حاسمة في التصميم الآلي للشبكة (Hussain, & Browse, 1998).وبالتالي، تم تطوير عدة طرق لإنتاج تصنيفات فعالة وكفوءة من ANNs. وأول تلك التصنيفات هي الترميز الثنائي المباشر لتشكيلة الشبكة، حيث يحدد كل بت (خانة) وجود أو عدم وجود اتصال واحد (Siddiqi & Lucas, 1998). يمكن أن تُستخدم هذه الطريقة لترميز أي بنية هندسية عصبونية. تعتمد الطرق الأخرى لترميز ANNs على التصنيف الثنائي للقواعد التي تصف البنية الهندسية للشبكة (Hussain, 2000). طريقة تصنيف البنى الهندسية الأساسية (Barrios et at., 2001) هي أسلوب آخر يعتمد على تعريف مجموعة أبيل Abel الجزئية بعنصر محايد في مجموعة البنى الهندسية العصبونية وهي تستثني تصنيف الشبكات غير القانونية، وتحتاج طول ترميز قصير جداً يكون مثالياً لترميز شبكات عصبونية بخرج واحد. يرمز هذا التصنيف أي نوع من شبكات Perceptrons متعددة الطبقات المُعممة بطبقة خفية واحدة. هناك أيضاً ميزة هامة جداً هي التغير أحادي البت في السلسلة التي تمثل نتائج الشبكة في بنية هندسية عصبونية مماثلة جداً، وتُحسّن أداء GA. يجب أن تُستخدم أيٌّ من طرق التصنيف هذه معامل تصالب ملائم. إلى جانب المعاملات الكلاسيكية، مثل المعامل أحادي النقطة، ثنائي النقطة، والمعامل الموحد، والمعاملات المصممة، فإن معامل هامينغ (H-X) (Barrios, Carrascal, Manrique, & Rios, 2003) المعتمد على مفهوم مسافة هامينغ يكون مخصصاً من أجل العمل مع تصنيف البنى الهندسية الأساسي باستغلال فوائده للحصول على أداء أفضل في البحث عن بنى هندسية عصبونية من معاملات التصالب الثنائية الأخرى.

العائق الرئيسي الآخر بخصوص استخدام ANNs هو مسألة التدريب. ففي حين يعطي تدريب الشبكات العصبونية أمامية الانتشار بانتشار خلفي معتمد على التدرج بخوارزمية عامل زخم نتائج جيدة عادة، فإنه لا يوجد ضمان بأن يكون الحل الذي تم الوصول إليه مثالياً. في الحقيقة، إحدى المشاكل مع هذه الطريقة هي أن كلاً من سرعة التقارب نحو الحل، وإمكانية الوصول إلى

حل يعتمدان على اختيار معدل التعلّم m والثابت التناسبي للزخم (Dai, McBeth, 1997)، لأنه يمكن أن يُنظر لتدريب ANNs كمسألة أَمْثَلة، تكون GAs أيضاً خياراً مناسباً للتعامل مع هذه المسألة عن طريق التبديل الكامل أو الجزئي لطريقة تعلّم الشبكة (Brown, & Card, 2000). يصرّح العالم Michalewicz بأنه إذا كانت هناك مشكلة ما حقيقية مقيمة في الطبيعة، فعندها تكون GA ذات الأعداد الحقيقية أسرع وأكثر دقة من GA المرمزة ثنائياً. وهذا هو السبب في وجود معاملات تصالب مختلفة لتدريب ANNs بـــ GA مرمزة بأعداد حقيقية: تصالب رادكلف المستوي (Radcliffe,1990)، BLX-a (Eshelman & Schaffer, 1993)، UNDX (Ono & Kobayashi, 1997), أو التصالب المورفولوجي (MX) (Barrios et at. 2003). لدى MX ميزة هامة لتوسيع وبشكل تكيّفي (بالاعتماد على قيم السلف) التخطيط المجالي المُعرّف بالآباء الذين أُخذ منهم النسل. وهو إعادة تفسير عملية التدرج المورفولوجية المستخدمة بشكل شائع جداً في عملية تقطيع الصورة المُرقمنة (D'alotto & Giardina, 1998) للحصول على مقياس تنوع وراثي على الانترنت. يزيد هذا المقياس سرعة البحث المحلية لـــ GA في عملية التدريب، التي هي العائق الرئيس المذكور من قبل الباحثين الذين يفضلون دمج GAs وطرق الهبوط التدريجي، بحيث يجعل الوقوع قيمة مثلى محلية أقل من المحتمل.

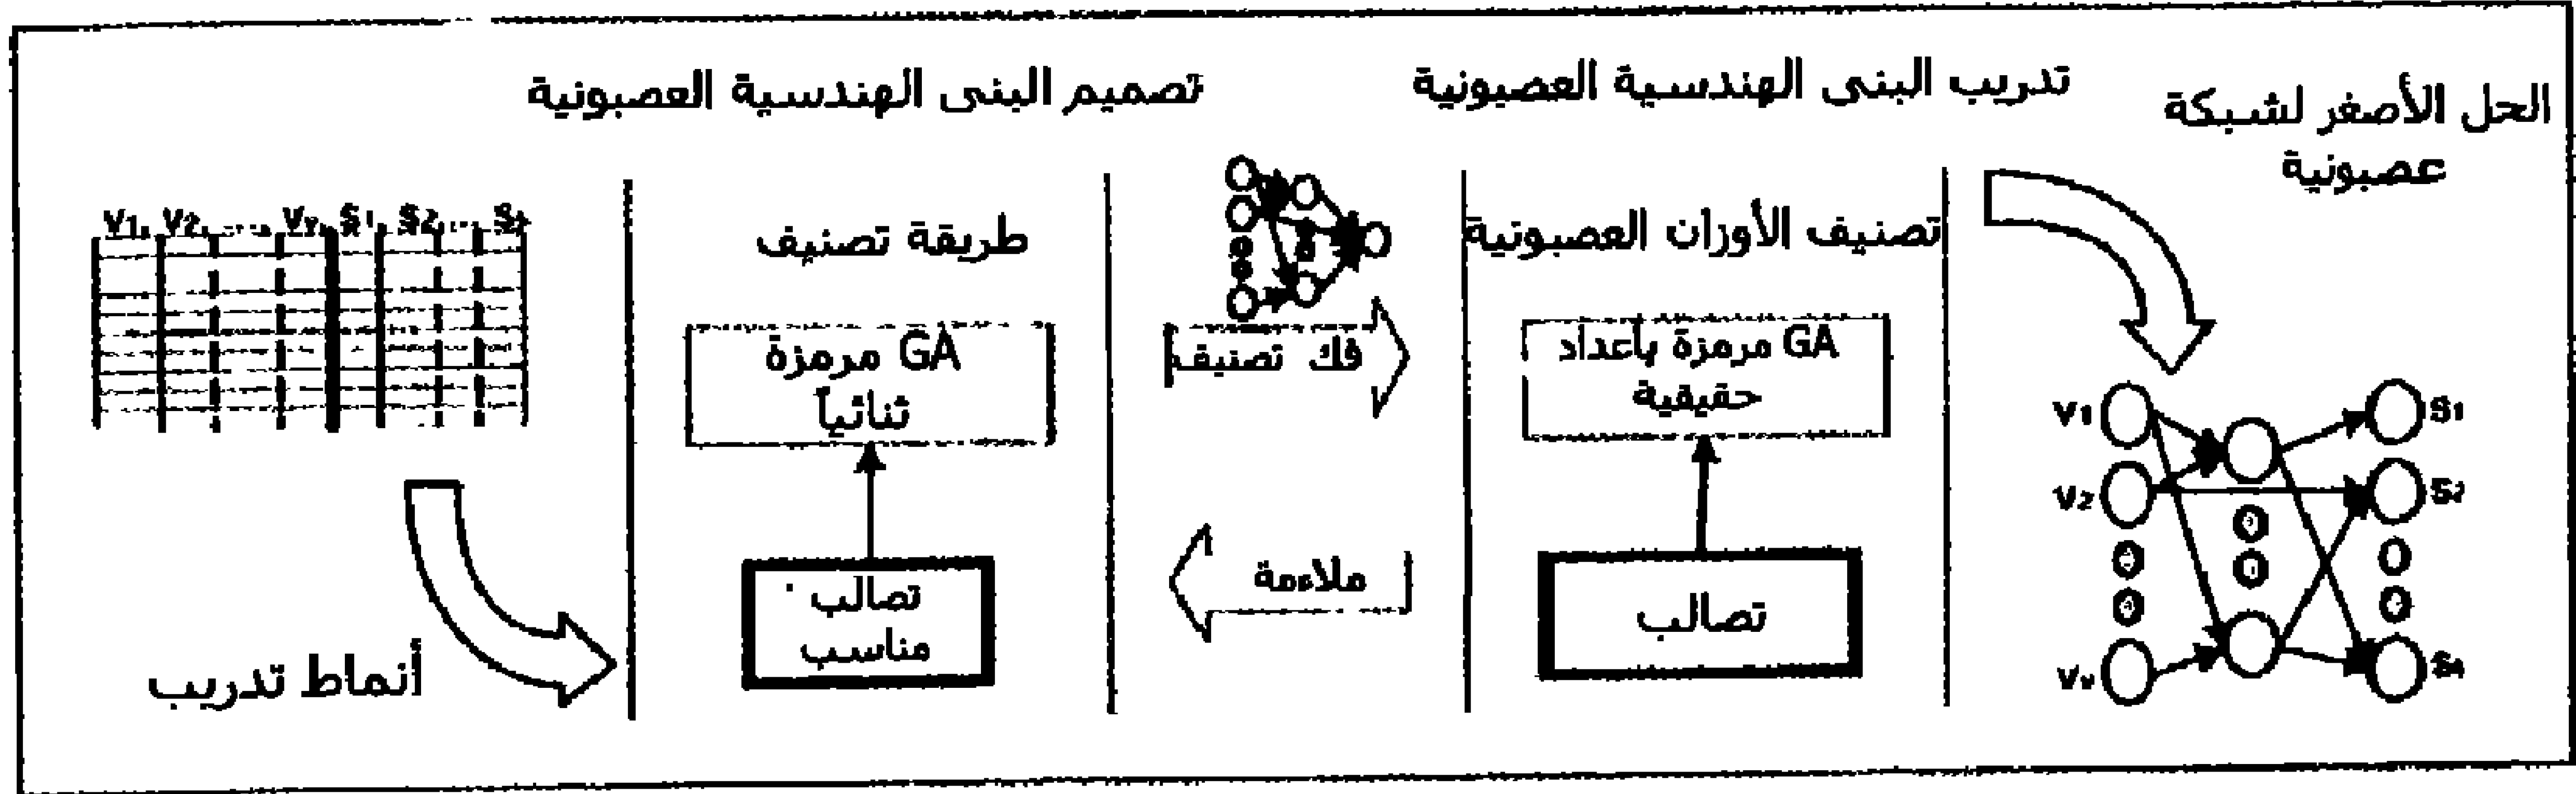
يصف هذا الفصل تقنيات تطورية من أجل بناء أنظمة ذكية ذاتية التكيّف مركبة من شبكات Perceptrons متعددة الطبقات. وهو يبين كيف يمكن - بإدخال مجموعة واحدة فقط من أنماط التدريب - أن تتعاون GA المرمزة ثنائياً بأعداد حقيقية لإنتاج شبكة Perceptron متعددة الطبقات مدربة بالعدد أصغر من العصبونات والاتصالات، والحصول على متوسط مربع خطأ قليل جداً من أجل مجموعة التدريب المُعطاة. أخيراً، تقدم مقارنات من ناحية سرعة التقارب والفعالية والدقة بين طرق تصنيف حقيقية وثنائية مختلفة، وتمت مناقشة معاملات التصالب. كما تم اختيار اختبارات مخبرية لعرض الميزات للطرق التطويرية المختلفة، وطرحت مسألة تشخيص سرطان الثدي، وتم حلها باستخدام شبكة Perceptron متعددة الطبقات المولّدة بـــ GAs.

النظام التطوري لبناء الشبكات

يشرح هذا الفصل تصميم نظام وراثي تتعاون فيه GA مرمزة ثنائياً قادرة على تصميم بنى هندسية عصبونية أمامية الانتشار وGA مرمزة بأعداد حقيقية قادرة على تدريب شبكات عصبونية أمامية الانتشار. الغرض من هذا النظام الوراثي هو إنتاج الشبكة العصبونية الصغرى، التي تولد متوسط مربع خطأ أقل من القيمة المحددة مسبقاً لمجموعة من أنماط التدريب، التي تصف المسألة المراد حلها.

مجموعة أنماط التدريب هذه هي دخل النظام. تعمل GAs المرمزة حقيقياً والمرمزة بأعداد حقيقية بالتوازي، انظر (الشكل 1).

الشكل (1) *البنية العامة لنظام تطوري لتصميم وتدريب الشبكات العصبونية*



سيكون من الضروري اختيار تصنيف ثنائي للبنى الهندسية العصبونية، الذي يوافق فضاء البحث ومعامل تصالب ملائم لتصميم بنى هندسية عصبونية. تستقبل GA المرمزة بأعداد حقيقية التي تدرب الشبكات العصبونية بنية هندسية مرمزة ثنائياً من مجتمع النموذج السابق.

من أجل التقييم بعد عملية الترميز. يتطلب هذا النموذج معامل تصالب، قادر على معالجة الصبغيات بأعداد حقيقية، وإيجاد قيم الأوزان للاتصالات العصبونية، التي تجعل متوسط مربع الخطأ أصغرياً لمجموعة أنماط التدريب. ثم يستخدم متوسط مربع الخطأ المُحقق بعد عملية التدريب لحساب الملاءمة للسلسلة الثنائية، التي تمثل هذه الشبكة العصبونية في المجتمع المُعالج بـــ GA الثنائية.

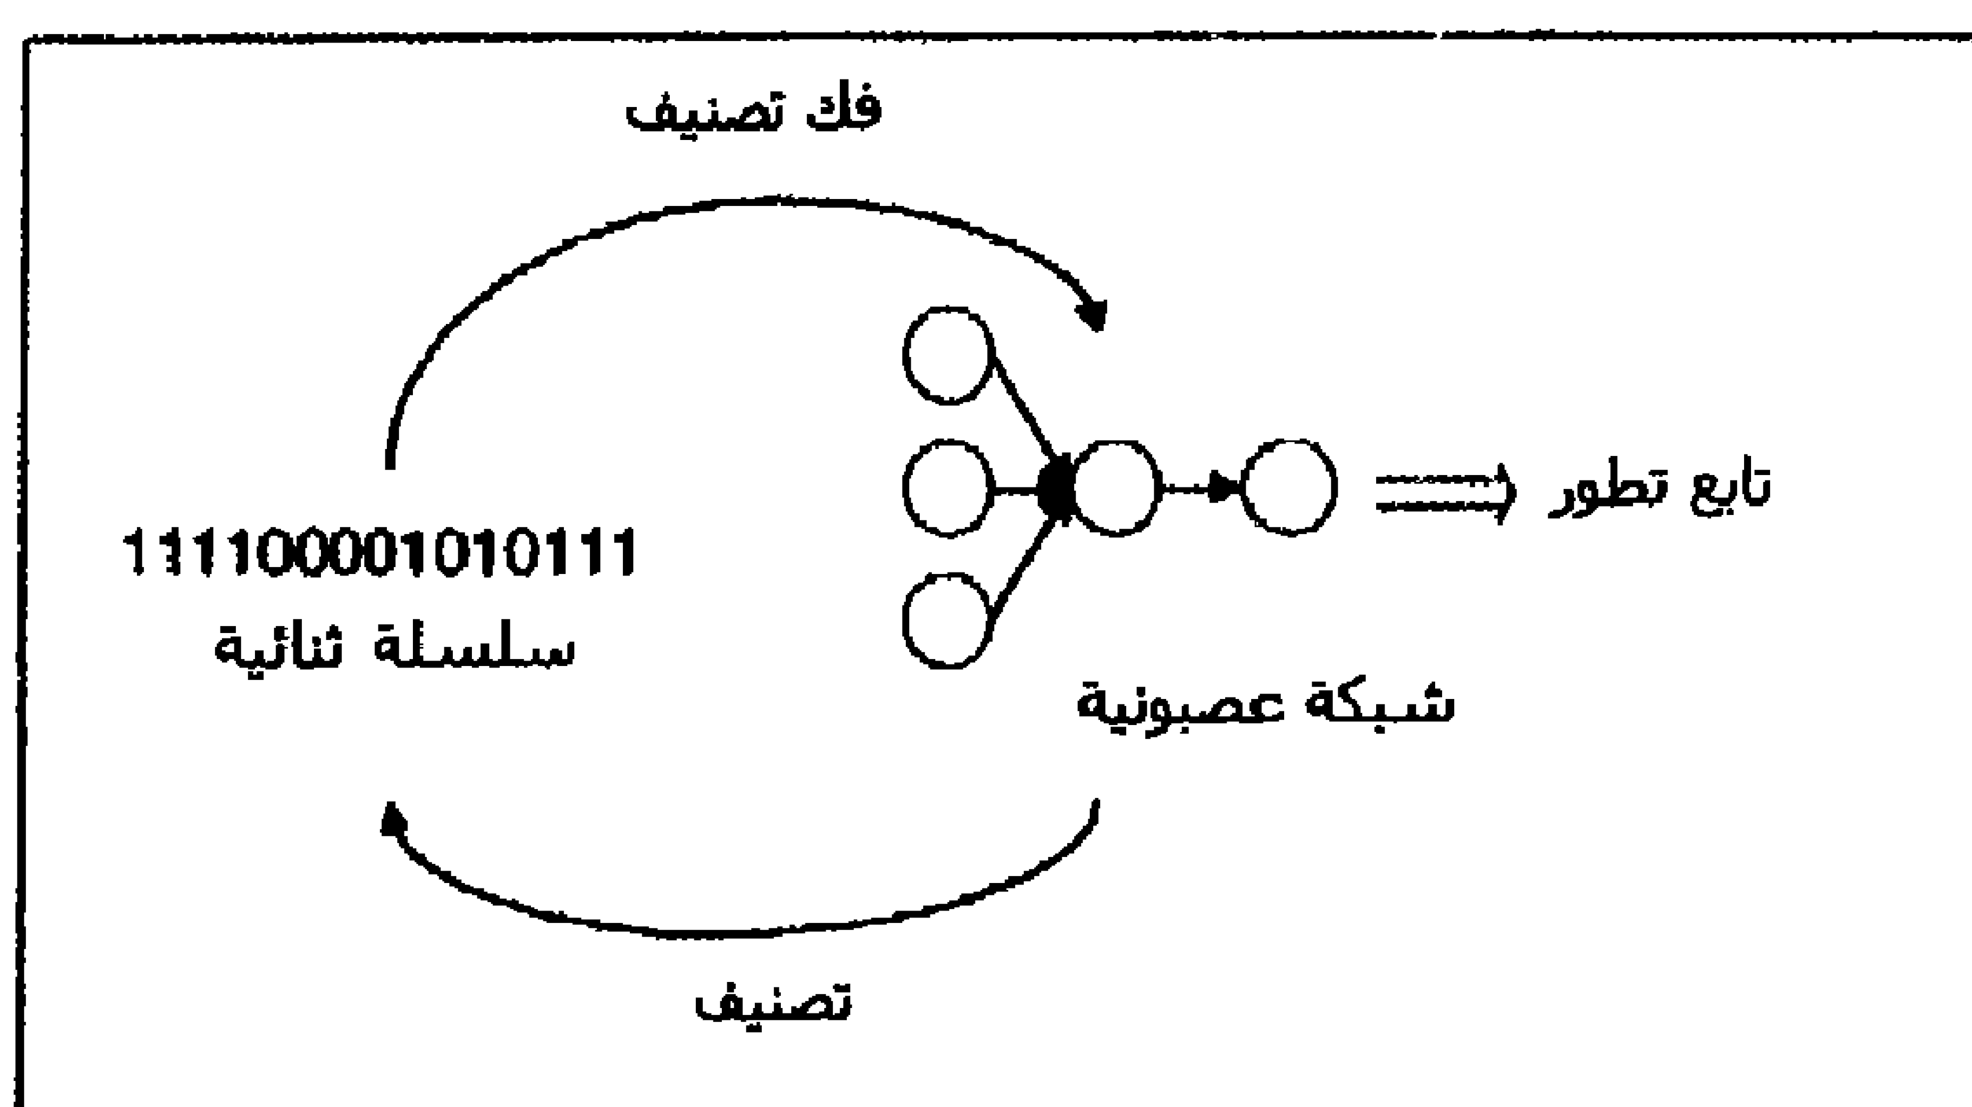
لأغراض توضيحية، يصف القسمان التاليان – أولاً – طرقاً مختلفة لتصميم بنى هندسية عصبونية صنعية، ومن ثم كيفية تدريب هذه البنى الهندسية باستخدام تصنيف أبجدية أصلية لا نهائية (أعداد حقيقية).

تصميم شبكات عصبونية بالخوارزميات الوراثية

الأمر الأول الذي يؤخذ بالحسبان عند تصميم شبكة عصبونية هو أن يكون لدى فضاء البحث عدد أصلي عالٍ. وذلك لأنه – اعتماداً على ماهية المسألة التي تتعامل معها – قد يُحتاج للعديد من العصبونات، ما يؤدي بالتالي إلى العديد من الاتصالات الممكنة بينها. وهكذا، فإن البحث من أجل البنية الهندسية المثلى – من حيث المبدأ – مرشح جداً لأن يُحل باستخدام GAs.

إن استخدام GA لتصميم شبكة عصبونية – مثل أي مسألة أمْثَلة أخرى تُطرق باستخدام هذه التقنية – يستدعي وجود طريقة تصنيف لنقاط فضاء البحث، التي هي في هذه الحالة شبكات عصبونية. وبالمثل، نحتاج لأن يكون تابع التقييم مثالياً. يفترض فيما يلي أن الحل الأمثل هو الشبكة العصبونية التي تعطي القيمة الصغرى لهذا التابع، بمعنى أنه تُعطى شبكتان عصبونيتان، والشبكة التي ملاءمتها أقل ستعتبر هي الحل الأفضل. وبالتالي فالغرض من GA هو جعل تابع التقييم أصغرياً، ويظهر (الشكل 2) مخطط لهذه المفاهيم بافتراض أنه تم استخدام أبجدية ثنائية عادية.

الشكل (2) *العناصر الأساسية المطلوبة لتصميم شبكات عصبونية بـ GAs*



الملاءمة التي تؤخذ عادةً من أجل سلسلة مُعطاة هي متوسط مربع الخطأ المُحقق أثناء تدريب خرج الشبكة العصبونية بفك ترميز هذه السلسلة. تُثقل قيمة الملاءمة عادةً بشروط أخرى، بحيث تأخذ بالحسبان حقائق كتعقيد البنية الهندسية العصبونية المرمزة. أي أن، السلاسل الفردية التي تمثل البنى الهندسية بعدد كبير من PE والاتصالات بينها تتعاقب أكثر من البنى الهندسية الأبسط، وذلك لأن لدى البنية الهندسية البسيطة سرعة تنفيذ أعلى وقابلية تعميم أكبر.

حالما تُقدر كافة السلاسل الفردية، يُطبق التكاثر الوراثي ومعاملات التصالب والطفرة لإنتاج الجيل (المجتمع) الجديد. ويتم تكرار هذه الخطوات حتى يقترب المجتمع من البنية الهندسية العصبونية المثلى من أجل حل مسألة مُعطاة.

تابع التقييم

إن عملية اختيار أو بناء تابع تقييم يعطي قيمة ملاءمة لسلسلة فردية في المجتمع، التي ترمز طبولوجية عصبونية هي عملية بسيطة نسبياً. يعتمد تابع التقييم f المستخدم عموماً بكثرة على

حساب متوسط مربع الخطأ للشبكة خلال عملية التدريب ومُثقل بشروط أخرى، التي تأخذ بالحسبان عدد الاتصالات في البنية الهندسية الناتجة. ينتج أحد توابع التقييم هذه الذي عادةً البنى الهندسية العصبونية الأصغر هو التالي:

$$f = MSE_{it}\left(\frac{Ca}{Ct}\right)$$

حيث أن: MSE – متوسط مربع الخطأ المكتسب خلال عملية التدريب بعد it تكرار. Ca – عدد الاتصالات في البنية الهندسية العصبونية الحالية. Ct – العدد الكلي للاتصالات الممكنة المسموحة بالتصنيف المستخدم.

طرق تصنيف البنى الهندسية العصبونية

إن التصنيف المستخدم بكثرة لتمثيل البنية الهندسية للشبكة العصبونية هو طريقة التصنيف المباشر (Bornholdt, & Graudenz, 1992) التي تمثل بشكل واضح كل اتصال بواسطة رقم ثنائي. إذا أعطيت بنية هندسية بـــ N عصبون، تكون المصفوفة التي تمثل مجموعة الاتصالات في هذه الشبكة هي مصفوفة بقياس N × N، ويرمز لها بالرمز W بحيث:

$$W = \begin{bmatrix} W_{11} & W_{12} & \dots & W_{1N} \\ W_{21} & W_{22} & \dots & W_{2N} \\ \dots & \dots & \dots & \dots \\ W_{N1} & W_{N2} & \dots & W_{NM} \end{bmatrix}$$

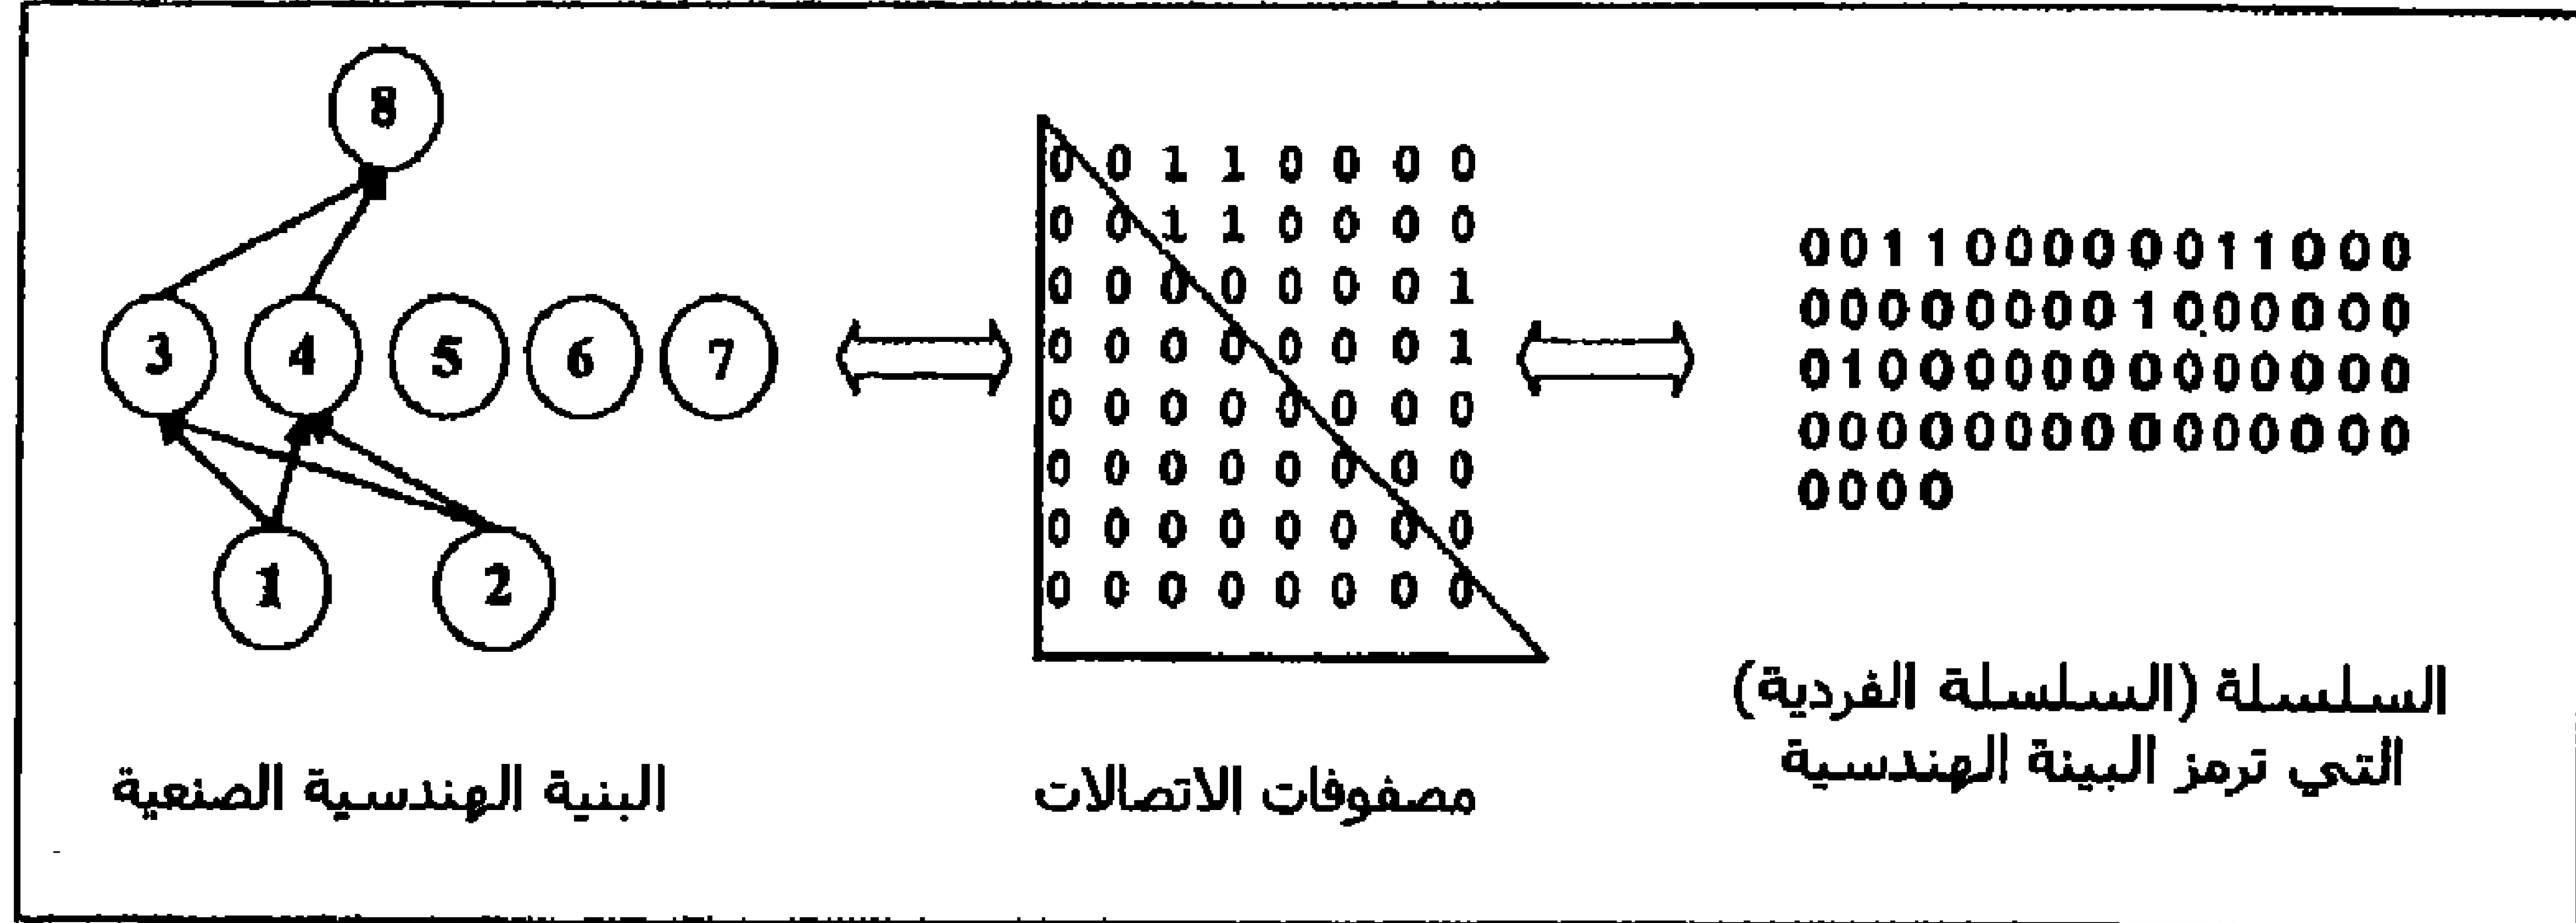
حيث أن: $W_{ij} = \{0, 1\}, \ \forall i, j = 1, 2, ..., N$

تمثل القيم W_{ij} وجود أو غياب الاتصالات. فإذا كان $W_{ij} = 1$، وعندئذ يوجد اتصال من العصبون i إلى العصبون j في الشبكة. ومن جهة أخرى، إذا كانت $W_{ij} = 0$، فلا يوجد عندها اتصال بين هذين العصبونين. إذا كانت المصفوفة تحتوي على أصفار على طول وتحت القطر الرئيسي، فإن البنية الهندسية العصبونية للشبكة الممثلة هي أمامية الانتشار. ومن جهة أخرى، إذا كان هناك أرقام غير صفرية، تكون البنية الهندسية العصبونية خلفية الانتشار. يعرض (الشكل 3) شبكة عصبونية أمامية الانتشار ومصفوفة اتصالاتها والسلسلة الثنائية التي تمثل بنيتها الهندسية. تستخدم طريقة التصنيف هذه N^2 بت لترميز البنى الهندسية خلفية الانتشار بـــ N عصبون، بينما يمكن أن يُخفض عدد البتات المطلوب لترميز البنى الهندسية أمامية الانتشار إلى $\frac{N(N-1)}{2}$.

تؤمن هذه الطريقة سرعةً كبيرة وسهولة لتطبيق عملية ترميز وفك ترميز الشبكات العصبونية كسلاسل ثنائية والعكس بالعكس. على أية حال، يكمن عائقها في أن البتات المطلوبة للتصنيف

هي عدد مربع، وبالتالي تكون البنية الهندسية العصبونية التي ستُرمز ضخمة، ومصفوفات الاتصال كبيرة جداً، وتستغرق GA مدة طويلة جداً لمعالجتها.

الشكل (3) *التصنيف المباشر للبنى الهندسية العصبونية*



تم تصميم تصنيفات أخرى لتقليل حجم السلاسل الفردية للمجتمع، التي تولدها طرق التصنيف المباشر. ومن هذه التصنيفات طرق التصنيف غير المباشر الهامة جداً (Kitano, 1994). وهي تعتمد على فكرة استخدام تمثيل وسيط بين مصفوفة الاتصالات والسلسلة التي ترمز البنية الهندسية. العضو البارز من طرق التصنيف غير المباشر للبنى الهندسية العصبونية هو طريقة التصنيف القواعدية grammar codification (Kitano, 1994)، التي تتضمن وصف البنية الهندسية بواسطة مجموعة من قوانين الاشتقاق المنتجة لقواعد ما، ومن ثم ترميز هذه القوانين بواسطة سلاسل ثنائية. يكون التمثيل الوسيط المختار من البنى الهندسية العصبونية والسلاسل التي ترمزها هو - في هذه الحالة - مجموعة من القوانين القواعدية.

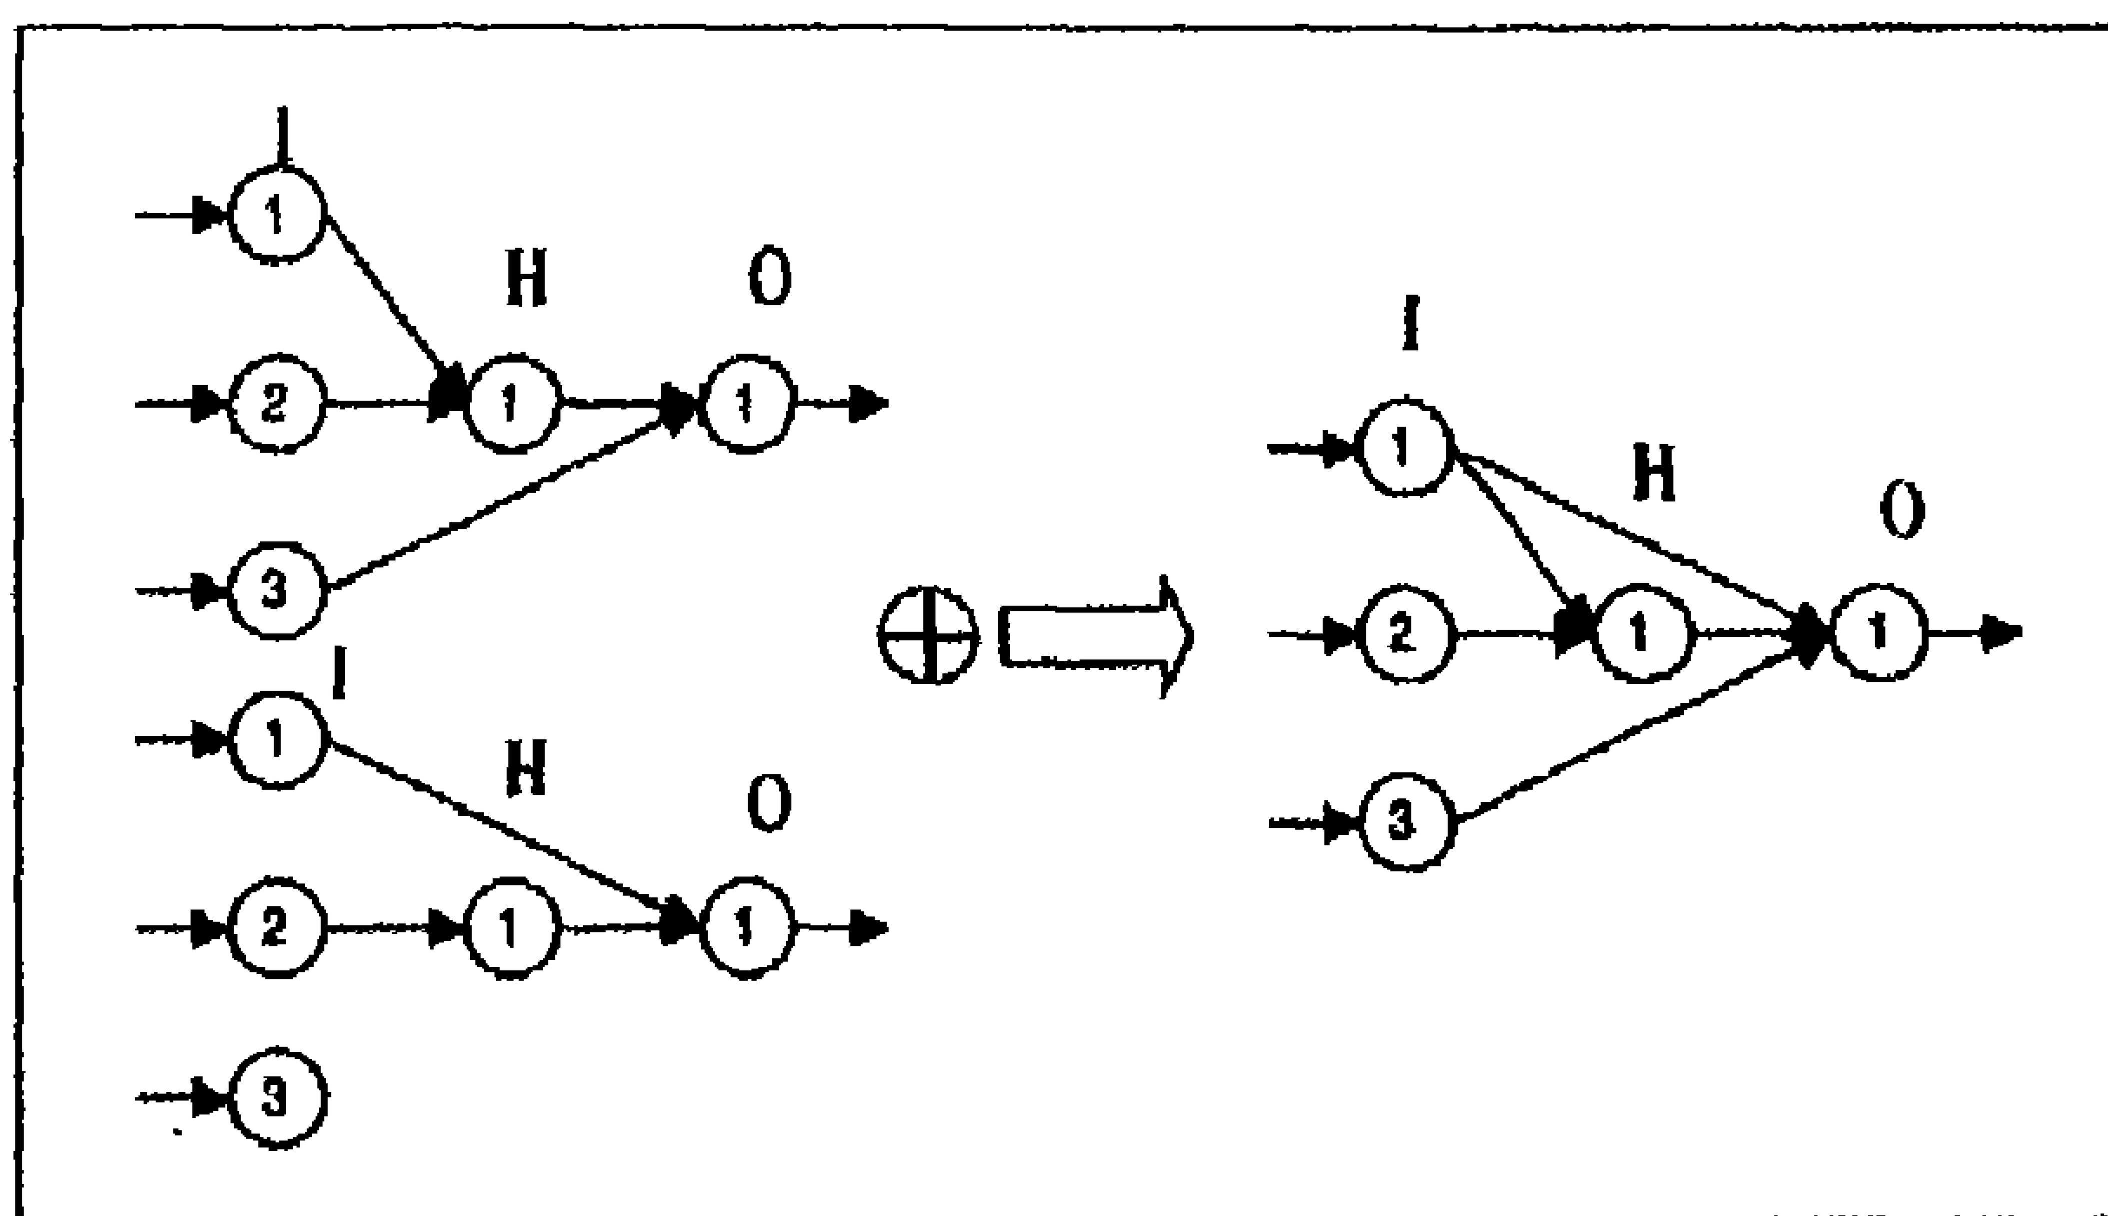
ويؤدي هذا إلى تخفيض طول السلاسل التي تشكل المجتمع إذا ما تمت مقارنتها بطريقة التصنيف المباشر. تتألف طريقة التصنيف القواعدية من قسمين: (1) بناء القواعد التي تكون كلماتها مجموعة من البنى الهندسية العصبونية التي ستستخدم، أي، فضاء البحث، (2) تصنيف قوانين اشتقاق القواعد بواسطة سلاسل ثنائية. من أجل شبكات عصبونية أمامية الانتشار بعصبوني دخل وخمس عصبونات خفية وعصبون خرج واحد، تحتاج طريقة الترميز القواعدية لـ 40 بت، في حين تأخذ طريقة التصنيف المباشر 64 بت. يكمن العائق لهذه الطريقة في أنه من الممل جداً تعريف القواعد في كل مرة تُبنى فيها شبكة عصبونية جديدة.

طريقة تصنيف البنى الهندسية الأساسي (Rios, Barrios, Carrascal, & Manrique, 2001) هي طريقة هامة أخرى، يمكن أن تُصنّف كطريقة تصنيف غير مباشر. وهي تعتمد على تشكيل

جبري لمجموعة من البنى الهندسية العصبونية أمامية الانتشار بطبقة خفية واحدة. ينتج هذا الوصف الجبري تصنيفاً ثنائياً، تُمثل فيه أية بنية هندسية عصبونية بواسطة سلسلة من البتات بطول أقصر من طريقتي التصنيف سابقتي الذكر. ترمز طريقة التصنيف هذه إلى مجموعة من كافة الشبكات العصبونية أمامية الانتشار مُصممة بعدد عصبونات دخل أعظمي I ووحدات خفية H ووحدات خرج O بالرمز $R_{I.H.O}$: يهمنا من مجموعة كافة الشبكات العصبونية الموجودة $R_{I.H.O}$ فقط المجموعة الجزئية $V_{I.H.O} \leq R_{I.H.O}$ لكافة الشبكات العصبونية الصحيحة. حيث تحتوي $V_{I.H.O}$ فقط على النقط التي تستطيع حل مسألة ما، ولا تحتوي على شبكات عصبونية غير قانونية.

بفرض وجود شبكتين عصبونيتين صحيحتين V وV'، تكون عملية التراكب بينهما – والتي يرمز لها بالرمز $V \oplus V'$ – هي اتحاد الاتصالات بين V وV'. يوضح (الشكل 4) عملية التراكب.

الشكل (4) *عملية التراكب.*



أي شبكة عصبونية صحيحة $b \in V_{I.H.O}$ أساسية أيضاً – وكذلك $b \in B_{I.H.O}$ – إذا وفقط إذا كانت b تمتلك اتصالاً مباشراً واحداً فقط من الدخل إلى طبقة الخرج. أو كان هناك اتصال واحد من الدخل إلى وحدة خفية واحدة، واتصال آخر من هذه الوحدة إلى عصبون الخرج.

تمتلك المجموعة الجزئية $B_{I.H.O} \subseteq V_{I.H.O}$ لكافة الشبكات العصبونية الأساسية ميزات هامة، لأن أي بنية هندسية عصبونية أمامية الانتشار معممة صحيحة يمكن أن تُبنى من هذه البنى الأساسية.

نحسب الآن العدد الأصلي للمجموعة $B_{I.H.O}$. يوجد هناك ما مجموعه I.O من ANNs بدون وحدات خفية، إضافة إلى I.H.O شبكة، حيث يكون خرج واحد مرتبط مع دخل واحد عبر عصبون خفي واحد، ولذلك، فإن العدد الأصلي لـــ $B_{I.H.O}$ هو $I.O.(H + 1)$. التصنيف الثنائي

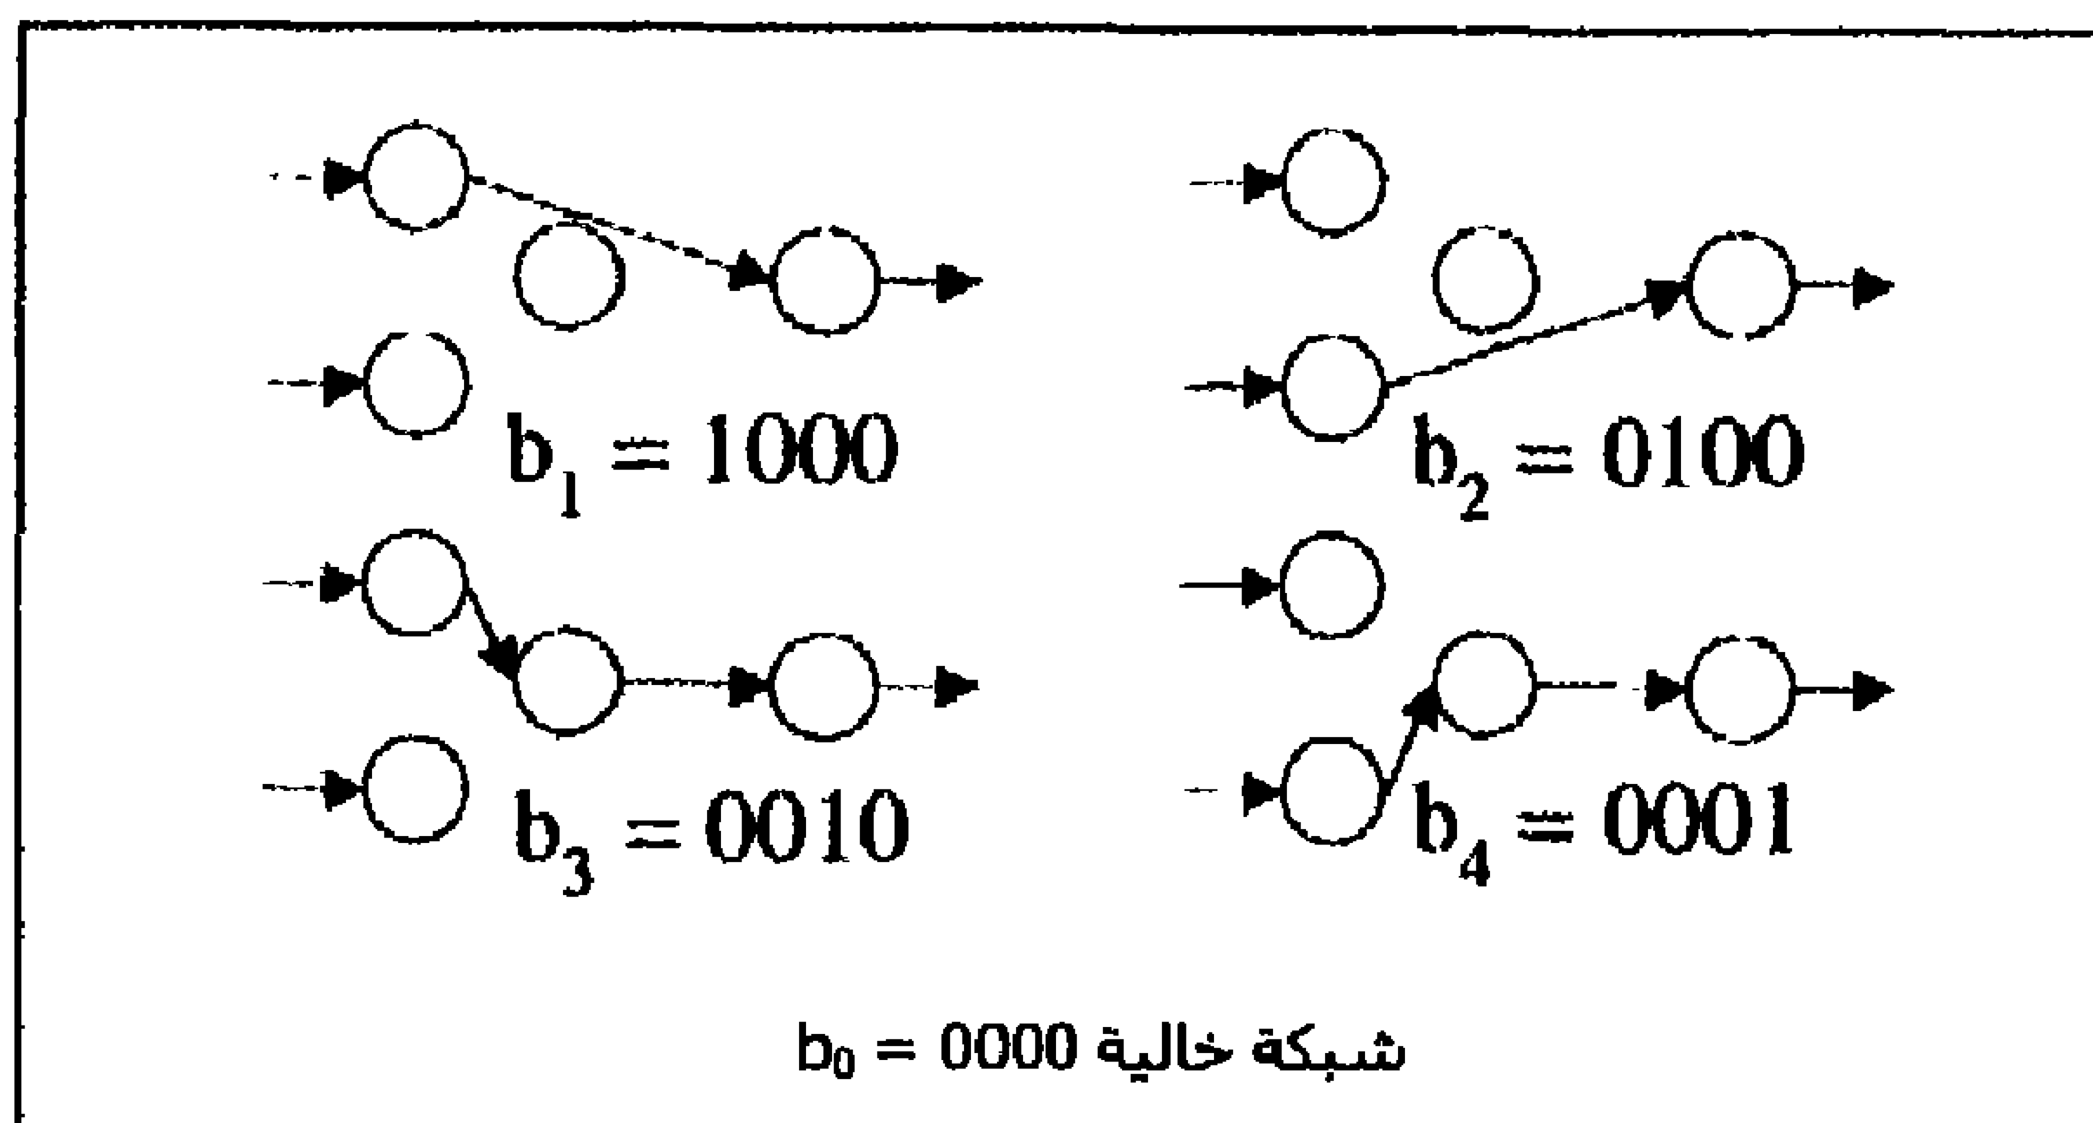
للبنى الهندسية العصبونية باستخدام هذه الطريقة يكون كالتالي: يوجد هناك I.O(H + 1) شبكة عصبونية أساسية، يمكن أن تُراكب لبناء بنى أكثر تعقيداً. وبالتالي، يمكن أن تدمج مجموعة من الشبكات العصبونية الأساسية $\{b_1, ..., b_{I.O(H+1)}\}$ في $2^{I.O(H+1)}$ طريقة مختلفة لبناء شبكات عصبونية صحيحة. وهكذا، يوجد توافق واحد إلى واحد بين مجموعة التراكيب الممكنة لكافة البنى الهندسية العصبونية الصحيحة والمجموعة $V^b_{I.H.O}$ لكافة السلاسل الثنائية، التي ترمز كل واحدة منها. مع كل هذه المقدمات المنطقية، فإن تصنيف كافة النقط في $V_{I.H.O}$ سيعتمد على تصنيف مجموعة من البنى الهندسية العصبونية الأساسية $B_{I.H.O} = \{b_1, b_2, ..., b_i, ..., b_{I.O(H+1)}\}$ ذات السلاسل الثنائية بطول I.O (H + 1) بت كما هو مبين في (الجدول 1).

الجدول (1) جدول التوافق لتصنيف بنى هندسية عصبونية

b1 → 1, 0, ..., 0, ... 0	
b2 → 0, 1, ..., 0, ... 0	
...	
bi → 0, 0, ..., 1, ... 0	يوضع 1 في الموقع i
...	
b1.0 (H + 1) → 0, 0, ..., 0, ..., 1	

يمكن أن تُرتب السلسلة $b_1, ..., b_{I.O(H+1)}$ بأية طريقة، ولكن عندها يجب المحافظة على نفس التسلسل المختار. الشبكة الخالية هي شبكة عصبونية بدون وجود أي اتصال. وتُرمز دائماً كسلسلة من الأصفار بطول I.O (H + 1). يبين (الشكل 5) مثالاً من جدول التوافق بين شبكات عصبونية أساسية وتصنيفها من أجل مجموعة $V_{1,2,1}$. حالما تُرمز كافة الشبكات العصبونية الأساسية، يمكن أن تُبنى أي شبكة عصبونية محتواةً في $V_{I.H.O}$ بتطبيق معامل OR (V) الثنائي على الشبكات الأساسية المرمزة. وهذا ينتج كافة السلاسل الثنائية المحتواة في المجموعة $V^b_{I.H.O}$. من السهل ترميز أي بنية هندسية عصبونية $v \in V_{I.H.O}$ بإيجاد الشبكات العصبونية الأساسية. التي يجب أن تُراكب للحصول على v ابتداءً من سلسلة أصفار بطول I.O.(H + 1) وبتحويل البت i إلى 1، إذا كان من الضروري أن تُراكب الشبكة العصبونية الأساسية i لتعطي v. عندما يُستخدم هذا التصنيف، يكون لدى المجموعة $V^b_{I.H.O}$ ميزتان هامتان. الأولى، أن فضاء البحث المُعرّف بالتصنيف المقترح يعطي فقط الحلول الممكنة للمسألة، أي أنه لا يوجد شبكات عصبونية غير قانونية. والثانية، توجد عدة سلاسل ثنائية التي تُرمز نفس ANN الصحيحة، لأن المجموعة $V^b_{I.H.O}$ ترمز مجموعة كافة التراكيب المفككة لكافة الشبكات العصبونية الصحيحة، وأي بنية عصبونية صحيحة تمتلك على الأقل تراكب مفككاً واحداً.

الشكل (5) *تصنيف ثنائي مختار من أجل $V_{1.2.1}$*



وهذه ميزة إيجابية للغاية حيث ستجد ANN GAs الأفضل، التي تحل مسألة ما أسرع، وذلك لأن عدة تصنيفات للبنى الهندسية العصبونية الأفضل تكون منتشرة في فضاء البحث.

معاملات التصالب الثنائية

يمكن أن يستخدم معامل التصالب لتحديد المجتمع. يلعب التصنيف المختار دوراً هاماً في هذا المعامل، فهو يعمل الآن مع رموز السلاسل الفردية بحيث تُحوّل كل نقطة في فضاء البحث إلى شعاع أو سلسلة بطول L - والتي في حالة التصنيف للبنى الهندسية العصبونية - تحتوي على أصفار وواحدات، بمعنى أنها تعمل بأبجدية محددة من عددين أصليين.

يتصرف التصالب وفقاً لاحتمالية مُعطاة منتجاً سلاسل فردية جديدة تدعى بالنسل مع بعض الخصائص الموروثة من السلاسل الفردية الأصلية. يُستخدم عادة n من الآباء لتوليد نسل جديد من سلسلتين فرديتين. بعض معاملات التصالب الأكثر أهمية موصوفة في التالي.

يأخذ معامل التصالب أحادي النقطة one-pointcrossover (Larrañaga, 1996) عشوائياً اثنين من الآباء من المجتمع الحالي، ويقطع سلسلتهما في نقطة ما ومنتقاة عشوائياً من كافة الواحدات (1s) الممكنة تدعى بموقع التصالب. يحدد هذا سلسلتين جزئيتين في كل زوج من السلاسل المستخدمة لأحداث السلسلتين الجديدتين اللتين تشكلان النسل. يُشكل النسل الأول باتصال تعاقبي للسلسلة الجزيئية الأولى لأحد الأبوين مع السلسلة الجزيئية الثانية للأب الآخر، وتنتج السلسلتان الجزئيتان الأخريان النسل الثاني. تم إيجاد معامل تصالب ثنائي النقطة two-point crossover من خلال البحث في سلوك معامل التصالب المعتمد على نقط متعددة، ليكون تحسيناً للمعامل أحادي النقطة. على أية حال، فإن إضافة نقاط تصالب أكثر عديم الفائدة لسلوك الخوارزمية

(Davis, 1991). يعتمد التصالب الموحّد uniform crossover (Syswerda, 1991) على تعريف قناع تصالب مركب من سلسلة عشوائية من البتات بنفس طول السلاسل الفريدة. يولد المعامل نسلين من كل زوج من الآباء بالطريقة التالية: سيكون الموقع i في سلسلة النسل الأول هو المورثة i من الأب الأول، إذا كان هناك قيمة 0 في الوقع i في قناع التصالب، وستكون المورثة i من الأب الثاني ما عدا ذلك. يُطبق القناع عكسياً من أجل النسل الثاني. ينشأ مصطلح التصالب الموحد من حقيقة أن قناع التصالب يُحسب عشوائياً وهناك نفس الاحتمالية ليكون 1 و0 في كل موقع من مواقع القناع.

يبدأ التصالب المعمم generalized crossover من سلسلتين ثنائيتين لإنتاج سلسلتين جديدتين كنسل. لتكن S = {0, 1} هي مجموعة كافة السلاسل الممكنة بطول خانة واحدة. وليكن g: S→{0,1...,21-1} تابع التحويل الذي يستخدم للحصول على فك ترميزها العادي كعدد صحيح. بما أن g تابع ثنائي، فإنه يمكن تعريف مجموعة أعداد صحيحة مكافئة كالمجموعة g(s). بالتالي، يمكن أن يُستخدم فضاء البحث أو مجموعة الأعداد الصحيحة المكافئة بشكل غير واضح. بفرض أن لدينا سلسلتان ثنائيتان a وb، سيكون النسل الناتج من معامل التصالب المعمم المختار عشوائياً للنقط 'a و'b كما يلي:

$$a' \in g - 1\ (g\ (a \wedge b),\ g\ (a \vee b)]);\ b' = g - 1\ (g\ (a) + g\ (b) - g\ (a'))$$

حيث أن ∧ - المعامل المنطقي and المطبق على بت إلى بت. ∨ - المعامل المنطقي or المطبق على بت إلى بت.

يأخذ معامل هامينغ Hamming Crossover (Corrascal, Manrique, Rios, & Rossi, 2003) بالاعتبار مسافة هامينغ بين مجموعة سلاسل السلف من أجل توليد نسلين. تكمن الميزة الأساسية لهذا المعامل في القدرة إلى توليد نسل، يكون أقل أو أكثر شبهاً بأسلافه (حسب مصطلح مسافة هامينغ) وفقاً لمقياس التنوع الوراثي الموجود في المجتمع. وبالتالي، يؤثر ديناميكياً على استكشاف الخوارزمية مقابل نسبة إمكانيات استكشافية. يعمل معامل تصالب هامينغ كالتالي: ليكن L هو طول الصبغيات، وd_H (s_i, s_j) هي مسافة هامينغ بين سلسلتين s_i وs_j. تُختار مجموعة n من صبغيات السلف $G = s_1, \ldots, s_n$ من المجتمع. ثم تُحسب مسافة هامينغ العظمى n بين سلفين S_{min} وS_{max} بحيث:

$$\forall\ S_i, S_j \in G,\ d\ (s_i, s_j) \le d_H\ (S_{min}, S_{max})$$

بعدئذ، يُحسب مقياس التنوع الوراثي G كالآتي: $g = \frac{h}{L}$. يوجه التنوع الوراثي g بشكل تكّيفي سلوك معامل هامينغ، الذي يولد نسلين من أجل كل مجموعة G من سلاسل الأسلاف.

سيكون النسلان أقل أو أكثر شبهاً بآبائهما كوسائل لتقليل أو زيادة التنوع في المجتمع للتوليد الثاني: يُستخدم تابع Cl (g) لتحديد عدد بتات النسل m = Cl (g)، التي يجب أن تكون مختلفة عن بتات الآباء. يعمل التابع Cl (g) كما يلي: إذا كانت قيمة g قريبة من الصفر (تنوع منخفض)، فإن تنوع المجتمع يجب أن يُزاد ليتمكن من الوقوع في قيمة محلية مُثلى أقل من المحتمل، أي نحتاج لاستكشاف أكثر. على النقيض من ذلك، إذا كانت قيم g كبيرة، يكون التنوع كبيراً، ويحتاج أن يُخفض التنوع، بمعنى يلزم تركيز البحث (استكشاف أكبر).

تدريب الشبكات العصبونية بخوارزميات وراثية

الأسلوب العادي لتدريب شبكات العصبونية باستخدام GAs هو بناء – ابتداءً من شبكة عصبونية وأنماط تدريب – GA تكون قادرة على إيجاد قيم أوزان الاتصالات، بحيث تجعل متوسط مربع الخطأ أصغرياً، أو تضمن بأنه على الأقل أخفض من القيمة التي اعتبرت مقبولة.

سنصف الآن البناء والعملية العامة لـــ GA من أجل شبكات عصبونية أمامية الانتشار.

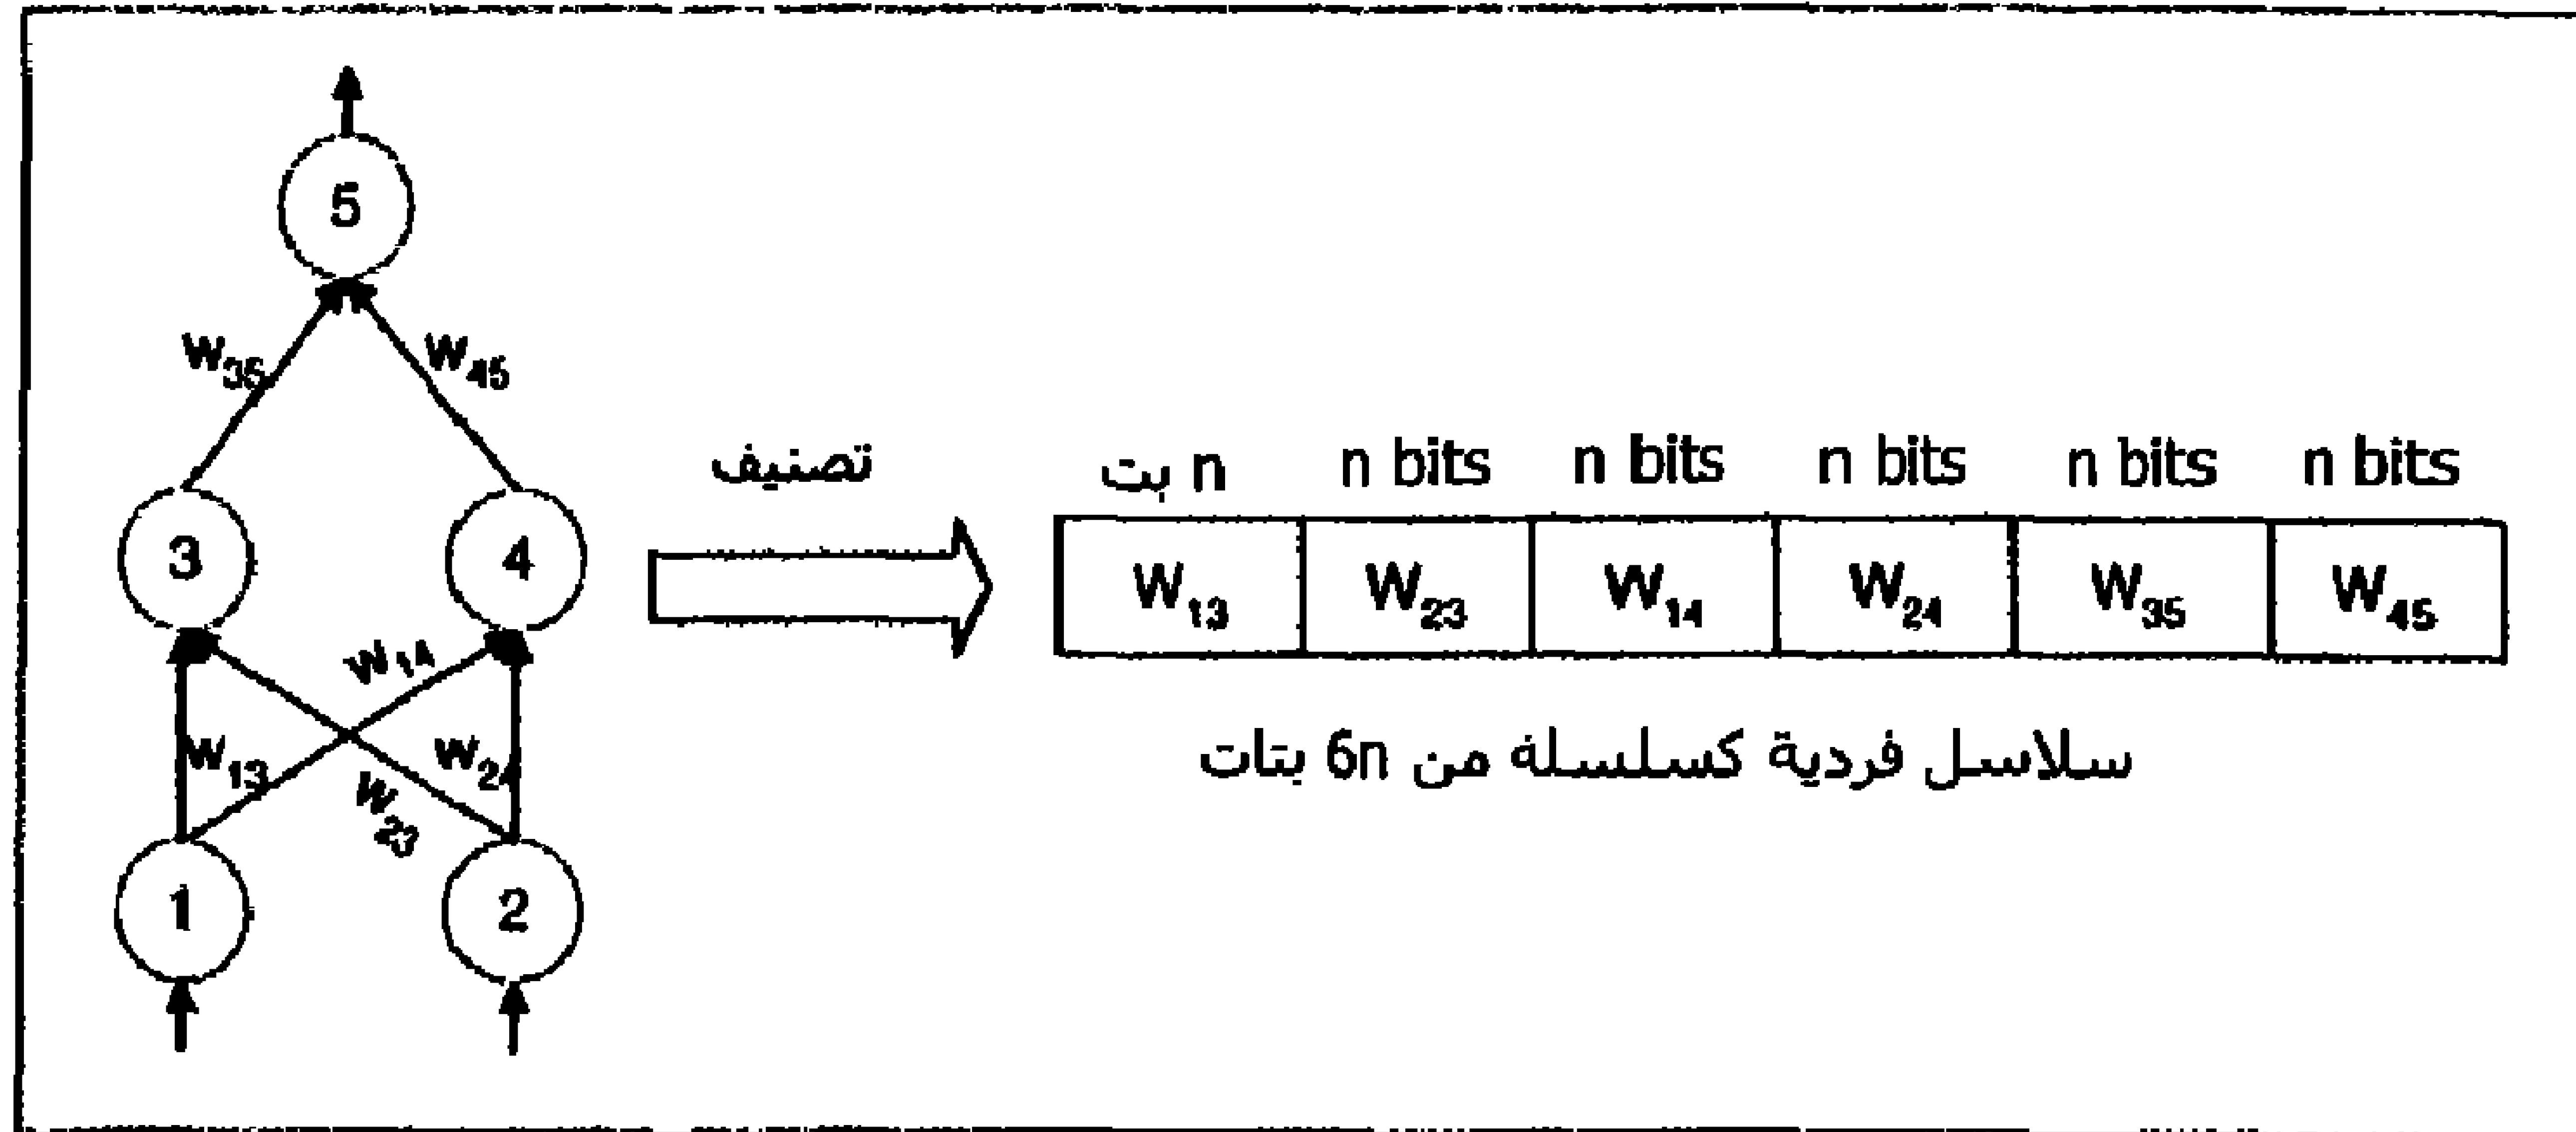
بفرض أن لدينا شبكة عصبونية جاهزة لأن تُدّرب، يُولّد المجتمع الابتدائي من السلاسل الفردية (الصبغيات)، وتُرمّز كل واحدة منها مجموعة من القيم لأوزان الاتصالات والانحيازات للشبكة العصبونية. ثم تُقيَّم الملاءمة لكل سلسلة فردية وهذا يستلزم تعيين موقع قيم الأوزان والانحيازات المرمزة بواسطة السلسلة الفردية لتقدير الاتصالات الشبكية وحساب متوسط مربع الخطأ. تستخدم مجموعة أنماط التدريب لتنفيذ هذه الحسابات.

وتكون قيمة الخطأ هي مقدار ملاءمة السلسلة الفردية. يُطبق بعد هذه المرحلة الابتدائية عادةً التكاثر الوراثي ومعاملات التصالب والطفرة لإنتاج توليدات جديدة حتى يحدث تقارب باتجاه مجتمع من السلاسل الفردية، التي تُرمّز مجموعة الأوزان التي تجعل خطأ الشبكة أصغرياً.

يمكن أن تُرمّز الأوزان بطرق عديدة، والطريقة الأكثر انتشاراً هي الترميز الثنائي لقيمة كل وزن للشبكة، وتكوين السلسلة الفردية باتصال تعاقبي لهذه الأعداد الثنائية في سلسلة من البتات كما يوضح المثال في (الشكل 6). من هذه الناحية، يُستخدم في أغلب الأحيان تصنيف رمادي لتقليل احتمالية التغيرات الصغيرة في البتات المؤدية إلى تغيرات كبيرة في.القيم التي تمثلها هذه البتات.

إن مخطط تدريب شبكة عصبونية كما هو مبين في (الشكل 6)، وطرق الترميز الموصوفة قد استخدمت في مشاريع بحث عديدة، وحققت نتائج مقبولة لمسائل مثل تطبيق التابع XOR بواسطة شبكات عصبونية أو بمجتمع ثنائي البت أو مسألة المشفر/فاك التشفير 4-2-4.

الشكل (6) *تصنيف ثنائي لأوزان اتصالات شبكة عصبونية*



يمكن أن يُنظر لتدريب ANNs كمسألة أمْثَلة، بحيث يجب أن يكون MSE أصغرياً بضبط قيم أوزان الاتصالات، ويجب - بالتالي - أن تكون الخوارزميات التطورية خياراً مناسباً للتعامل مع هذه المسألة. هذه المسألة هي ذات قيم حقيقية في الطبيعة، كما أن أوزان الاتصالات لشبكة Perceptron متعددة الطبقات هي أعداد حقيقية. وبالتالي، فإنه يمكن التوقع بأن تعطي GAs باستخدام تصنيف أعداد حقيقية لتمثيل أوزان الشبكة العصبونية أفضل النتائج (Michalewicz, 1999). المشكلة الرئيسية التي تظهر عند استخدام هذا النوع من التصنيف بـــ GAs هي قضية معاملات التصالب، مثل أنه لا يمكن استخدام معاملات تصالب معتمدة على إعادة دمج المورثات من الآباء لتوليد النسل. بفرض لدينا سلسلتي أعداد حقيقية $a = a_1, a_2, ..., a_L$ و $b = b_1, b_2, ..., b_L$. مع $a_i, b_i \in R, \forall i \in \{1, ... L\}$ ستؤدي إعادة دمج المورثات من الآباء بأية طريقة كانت إلى سلاسل بطول L من النوع $C = C_1, C_2, ..., CL$ بحيث $\forall i \in \{1, ..., L\}\ C_i \in \{a_1, ..., a_L, b_1, ..., b_L\}$ كنسل. أي أنه، ستستخدم نفس المورثات (الأعداد الحقيقية) التي ظهرت في المجتمع الأصلي - ولو كانت في مواقع مختلفة - طوال عملية التطور. في هذا الوضع، سيكون معامل واحد فقط قادراً على توليد مورثات جديدة هو معامل الطفرة، الذي يعني أنه بإعطاء الاحتمال المنخفض لاستخدامها بشكل عام، لن تتقارب الخوارزمية. التقنية الجديدة للتعامل مع GAs المرمزة بأعداد حقيقية هي التصالب المورفولوجي الرياضي mathematical morphology crossover الذي تم تطويره مؤخراً للعمل على GAs مرمزة بأعداد حقيقية (Barrios et at., 2001). من أجل تدريب ANNs لـــ GAs مرمزة بأعداد حقيقية يُحسن معامل التصالب هذا سرعة التقارب، ويكون أقل احتمالاً للوقوع في قيمة مُثلى محلية عند استخدام الانتشار الخلفي بخوارزمية تدريب ذات معامل زخم (Barrios, Carrascal, Manrique, & Rios, 2000).

لتكن D_R نقطة في فضاء البحث معرفة بالسلسلة $s = (a_0, a_1, ..., a_{l-1})$ حيث $a_i \in R$. يعمل هذا المعامل مع كل مورثة الآباء بشكل مستقل للحصول على مورثة خاصة في كل سليلين. لتكن $s_1, ..., s_n$ هي أعداد فردية من السلاسل المختارة من المجتمع الحالي التي ستُصالب. تُعرف مصفوفة الأسلاف بقياس $n \times L$ كالآتي:

$$G = \begin{bmatrix} a_{10} & a_{11} & \dots & a_{1l-1} \\ a_{20} & a_{21} & \dots & a_{2l-1} \\ \dots & \dots & \dots & \dots \\ a_{n0} & a_{n1} & \dots & a_{nl-1} \end{bmatrix}$$

حيث أن: $S_i = (a_{i0}, a_{i1}, ..., a_{i, L-1}), i = 1, ..., n$

يعمل معامل التصالب مع كل عمود $f_i = (a_{1i}, a_{2i}, ..., a_{ni})$ في المصفوفة G بالحصول على المورثات O_i وO'_i. وبالتالي ستكون نتيجة تطبيق المعامل على المصفوفة G – بالتالي – سليلين جديدين $O = (O_0, O_1, ..., O_{L-1})$ و$O' = (O'_0, O'_1, ..., O'_{L-1})$. ويكون الإجراء المستخدم من قبل هذا التصالب لتوليد سلاسل النسل الجديد: $O,O' \in DR$ من الآباء $s_1, s_2, ..., s_n$ في المصفوفة G هو كالآتي:

1. يُطبق المعامل التدرجي المورفولوجي – $gb(fi): D \rightarrow R$ على كل شعاع fi، $i= 0,1 .., L-1$ مع عنصر بناء b معرف كما يلي:

$b(x) = 0, \forall X \in D_b, D_b = \{-E (n/2), ..., 0, ..., E (n/2)\}$

E (X) – هو القسم الصحيح لــ X، تُحسب q_i كقيمة كما يلي:

$g_i = g_b (f_i) (E (n/2) + 1)$، $i \in \{0, 1, ..., L - 1\}$

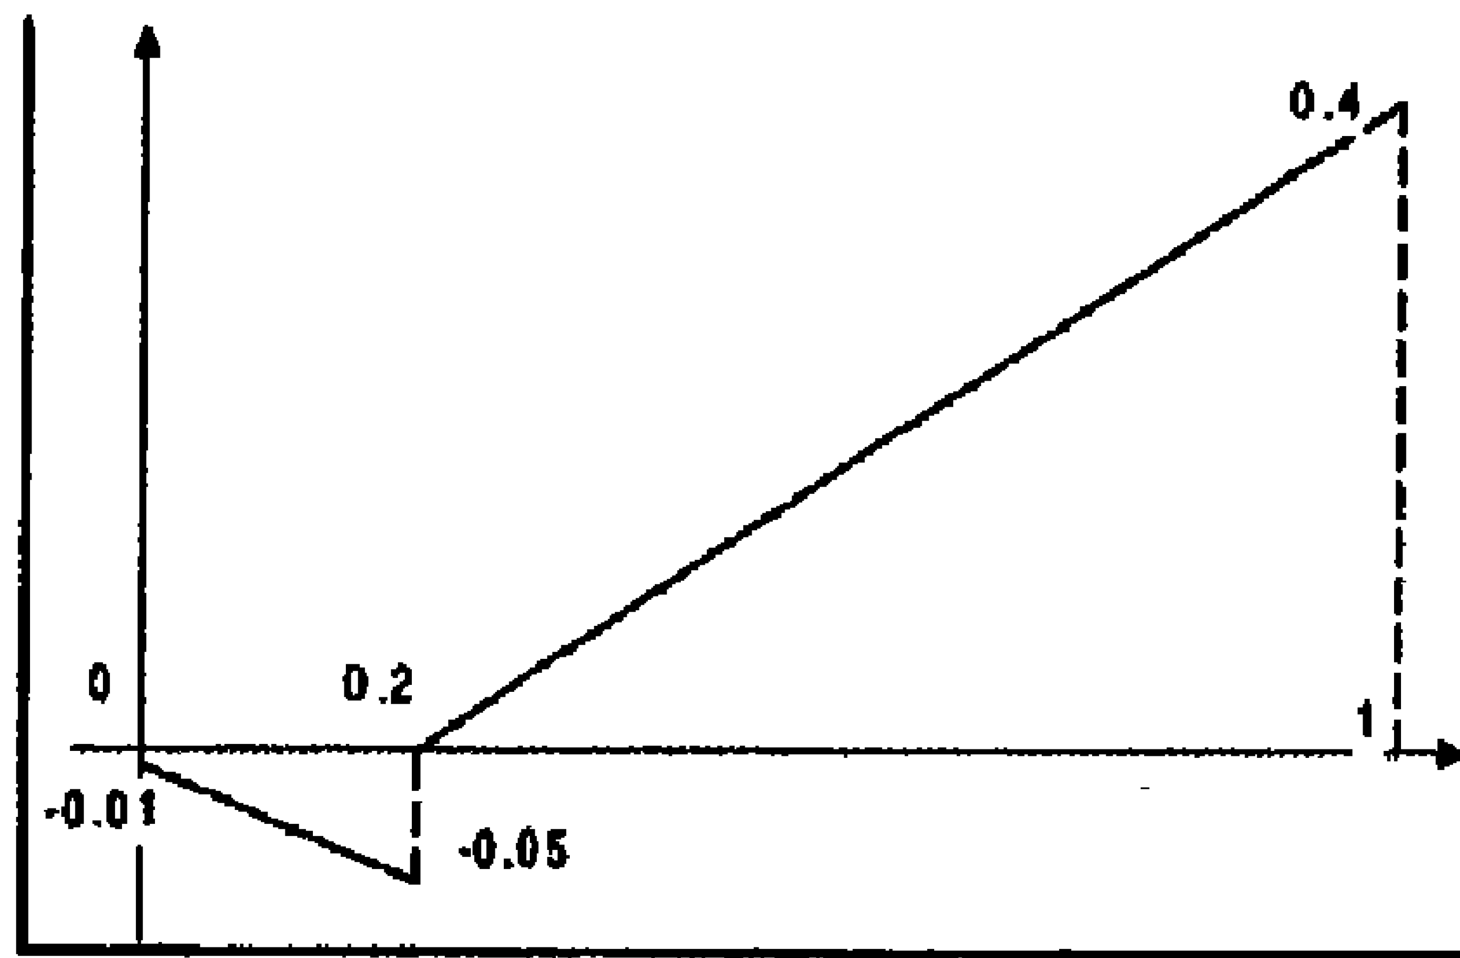
حالما يُطبق التدرج المورفولوجي على الصور، فإنه يعيد قيماً عالية عندما تكتشف انتقالات مفاجئة في قيم السويات الرمادية، ويعيد قيماً منخفضة إذا كانت البكسلات المُغطاة بالنافذة (عنصر البناء) متشابهه، يعطي g_i مقياساً لاختلاف المورثة i في السلاسل الفردية المنتقاة للتصالب. إذا كانت قيمة g_i كبيرة، فيكون المجتمع مشتتاً، أما إذا كانت منخفضة، فتكون قيم تلك المورثة متقاربة.

2. ليكن $cl: R \rightarrow R$ تابع معطى، والمورثة العظمى مُعرفة كالتالي: $g_{i\,max} = max (f_i) - Cl (g_i)$. وبطريقة مماثلة، تكون المورثة الصغرى معرفة كالآتي: $g_{i\,min} = min (f_i) + Cl (g_i)$. تحدد هذه القيم مجال التصالب $C_i = [g_{i\,min}, g_{i\,max}]$، الذي تؤخذ منه عشوائياً القيمة المرغوبة O_i. تُحسب المورثة i للسليل الآخر O'_i من داخل مجال التصالب باستخدام العلاقة التالية: $O'_i = g_{i\,max} + g_{i\,min} - O_i$.

يكمن الهدف الآن في الحصول على قانون يمكن أن يتحكم ديناميكياً بمدى مجال التصالب لجعل الوقوع في الحدود الدنيا المحلية أقل من المحتمل، والحصول على سرعة تقارب عالية. عندما تكون السلاسل الفردية التي ستصالب متنوعة (يتضمن قيمة عالية من التدرج). يكون مجال التصالب المصنوع ضيقاً وفقاً للقيم (f_i) max و(f_i) min. ويمكن أن يُبحث المجال من أجل القيمة المثالية بسرعة أكبر. من جهة أخرى، إذا كانت السلاسل الثنائية التي ستصالب متشابهة جداً (التدرج قريب من الصفر) – ما يعني أن المجتمع متقارب – عندها من المستحسن توسيع المجال [(f_i) min (f_i), max] للسماح باستكشاف نقط جديدة في المجال، وبذلك يتم تجنب التقارب الممكن إلى قيمة مُثلى محلية. هذه الإمكانية لتوسيع أو تطبيق مجال التصالب بالاعتماد على قيمة التدرج g_i معطية بالتابع CI المبين على (الشكل 7)، وهو مُعرّف في المجال [0.1] بحيث يجب أن يجعل المجتمع سوياً (عيارياً) في المدى نفسه. إن تطبيق هذا التابع في معامل التصالب الموصوف فعال جداً، حيث يمكن لكل زوج من السلاسل الثنائية الجديدة أن يُولّد عن طريق تكاثر واحد فقط.

يكون (g_i)j موجباً، عندما يكون g_i أكبر تماماً من 0.2 جاعلاً مجال التصالب أضيق. في هذه الحالة، يحدث التضييق الأعظمي عند j(1) = 0.4. من جهة أخرى، تكون قيم j (g_i) سالبة إذا كان $g_i \le 0.2$، أي أن مجال التصالب مُوسّع، ويحدث التوسع الأعظمي عند j (0.2) = -0.05. ابتداءً من هذه النقطة، تصبح قيم التابع أصغر فأصغر، بينما تهبط قيمة التدرج حتى تصل إلى القيمة 0.01- عند $g_i = 0$.

الشكل (7) *التابع j المستخدم من قبل التصالب المورفولوجي الرياضي.*



$$\varphi(g_i)=\begin{cases}-(0.2\cdot g_i)-0.01 & \text{if} \quad g_i \le 0.2\\ (0.5\cdot g_i)-0.1 & \text{عدا ذلك}\end{cases}$$

النظام التطوري لتصميم وتدريب الشبكات العصبونية

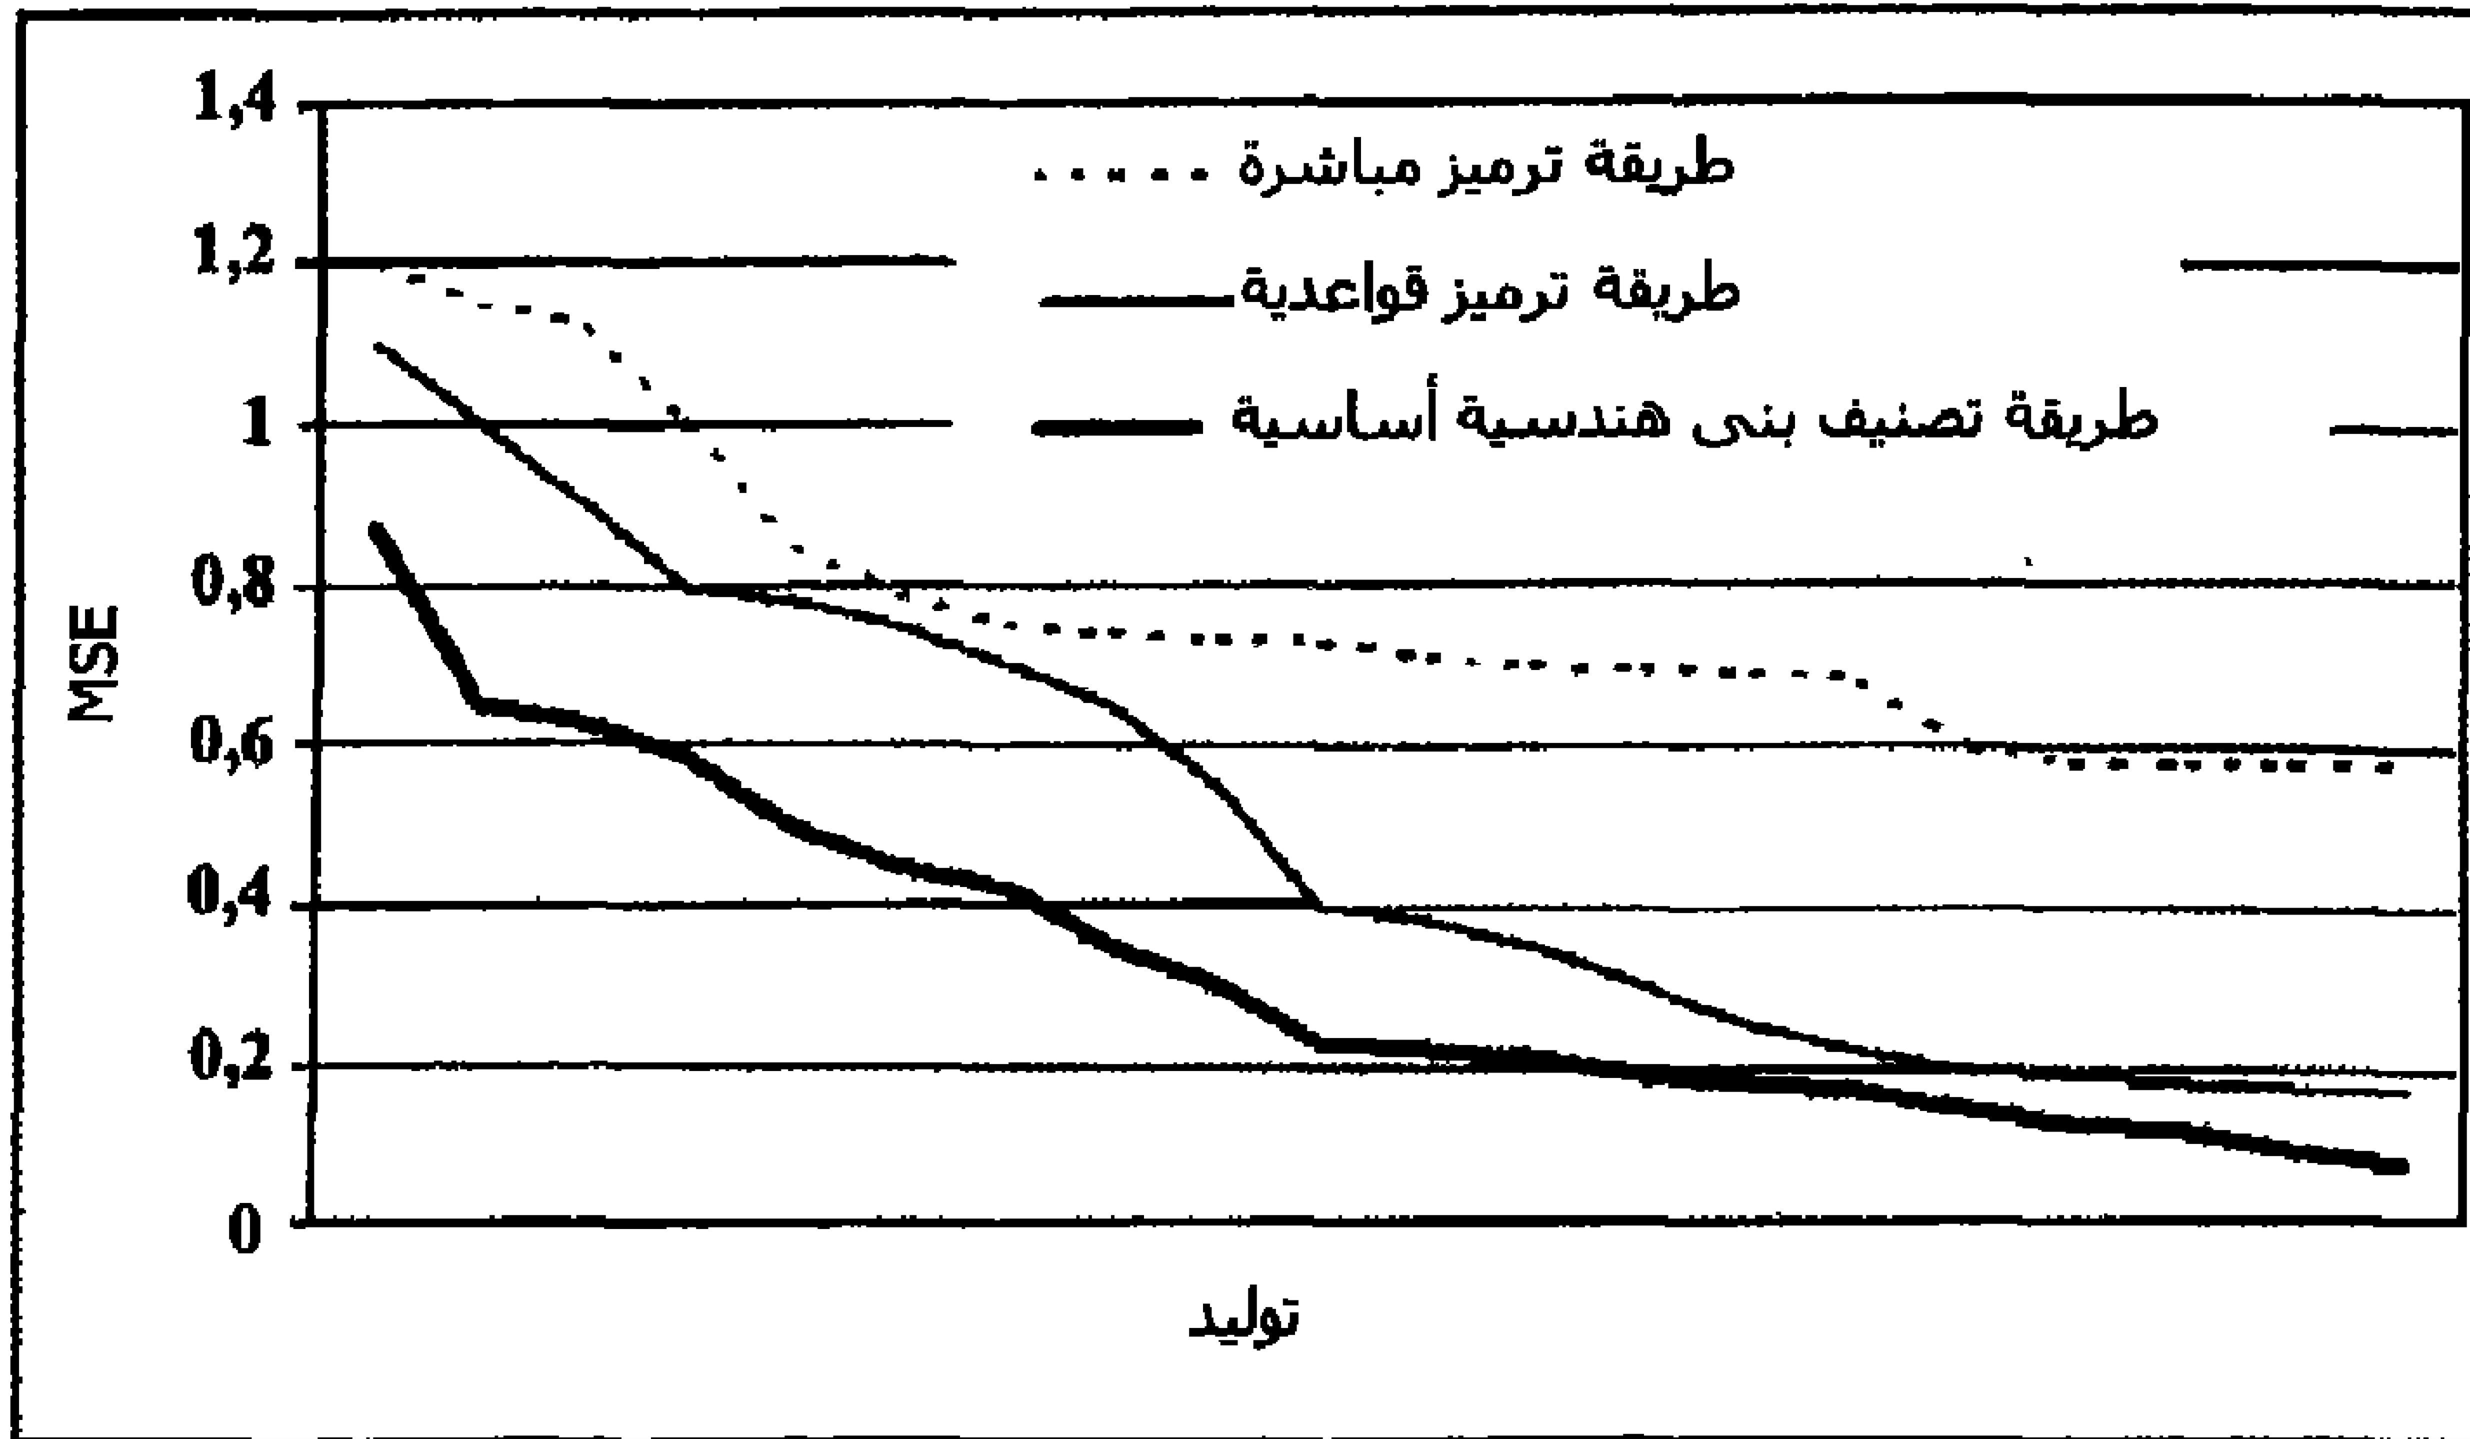
يقارن هذا القسم نتائج مجموعة اختبارات تجريبية، تم تنفيذها بطرق تصنيف البنى العصبونية ومعاملات التصالب الثنائية، ومعاملات التصالب المُرمزة بأعداد حقيقية المشروحة سابقاً. الغرض من هذا القسم هو انتقاء المعاملات الأفضل لبناء النظام التطوري، الذي يمكن أن يُستخدم لبناء أنظمة عصبونية ذكية ذاتية التكيّف. النتائج التجريبية متعلقة بسرعة التقارب وحجم الشبكات الناتجة. تمت مقارنة طريقة تصنيف البنى الهندسية الأساسية بمعامل هامينغ المستخدمة في النموذج التصميمي للبنى الهندسية العصبونية في النظام التطوري مع طرق التصنيف القواعدية والمباشر. كما تمت مقارنة أداء معامل تصالب هامينغ مع لتصالبات أحادية النقطة، وثنائية النقطة، ومعممة، وموحدة. وقد استخدمت طريقة البنى الهندسية الأساسية في جميع الحالات. أخيراً، تمت مقارنة أداء التصالب المورفولوجي لتدريب ANNs مع الانتشار الخلفي بعامل الزخم وتصالب رادكليف المستوي وتصالب وراثي أو مولّف. تظهر النتائج المذكورة تفوق التصالب المورفولوجي بشكل واضح من حيث سرعة التقارب، واحتمالية أقل للوقوع في قيمة مثلى محلية (Barrios et at., 2000). اختيرت وضعيات وراثية مشابهة لتلك التجارب. ولذا، استخدمنا استراتيجية تكاثر تناسبية، تُقرِّر إمكانية التكاثر فيها وفقاً لملاءمة كل سلسلة فردية. وضع احتمال الطفرة مساوياً لـــ 0.05، واستخدم معامل التصالب باحتمال مقداره 0.6. من أجل كل تجربة، قمنا بتشغيل 100 محاولة لـــ 1000 توليد، وحسبنا القيمة الوسطية، وحُسبت الملاءمة لكل شبكة عصبونية في المجتمع باستخدام العلاقة (1). استخدم التصالب المورفولوجي كخوارزمية تعلّم. اُختيرت مسألة المُشفر/فاك التشفير لإظهار سرعة التقارب والحجم الناتج للبنى الهندسية العصبونية الأساسية، ومقارنتها بطرق الترميز القواعدية والمباشر.

يبين (الشكل 8) نتائج البحث – من حيث سرعة التقارب – عن الشبكة الأفضل، التي تحل مسألة المشفر/فاك التشفير، بترميز البنى الهندسية بحد أعلى من أربعة واحدات دخل وخرج و8 عصبونات خفية (4-8-4). حُسبت الملاءمة للسلاسل الثنائية بعد تنفيذ 50000 تكرار تعلّم، ورُسم معدل MSE لأفضل 10 سلاسل ثنائية من المجتمع مقابل التوليد.

بمعزل عن حقيقة أن أداء طريقة تصنيف البنى الهندسية الأساسية أفضل بشكل واضح من الطرق الأخرى. يجب أن نذكر بأنه في هذه التجارب يتجه خط تطور نموذجنا إلى تقارب أسرع بكثير بعد حدوث عدة تكرارات. يظهر (الجدول 2) ناتج الحلول النهائية بكل طريقة. نجد من هذا الجدول، بأن طريقة تصنيف البنى الهندسية الأساسية لا تتقارب أسرع فقط، وإنما تحصل أيضاً على شبكات عصبونية أصغر. أُنتجت باستخدام طريقة التصنيف هذه البنى الهندسية 4-0-4 و4-1-4 باتصالات مباشرة من المداخل إلى المخارج خلال 89 % من عمليات التنفيذ، وهذا الأمر مرغوب

به جداً حسابياً عندما تعمل هذه الشبكات كجزء من نظام ذكي لحل المسألة، التي صُممت هذه الشبكات لأجلها.

الشكل (8) *عملية التقارب في مسألة المشفر/فاك التشفير*



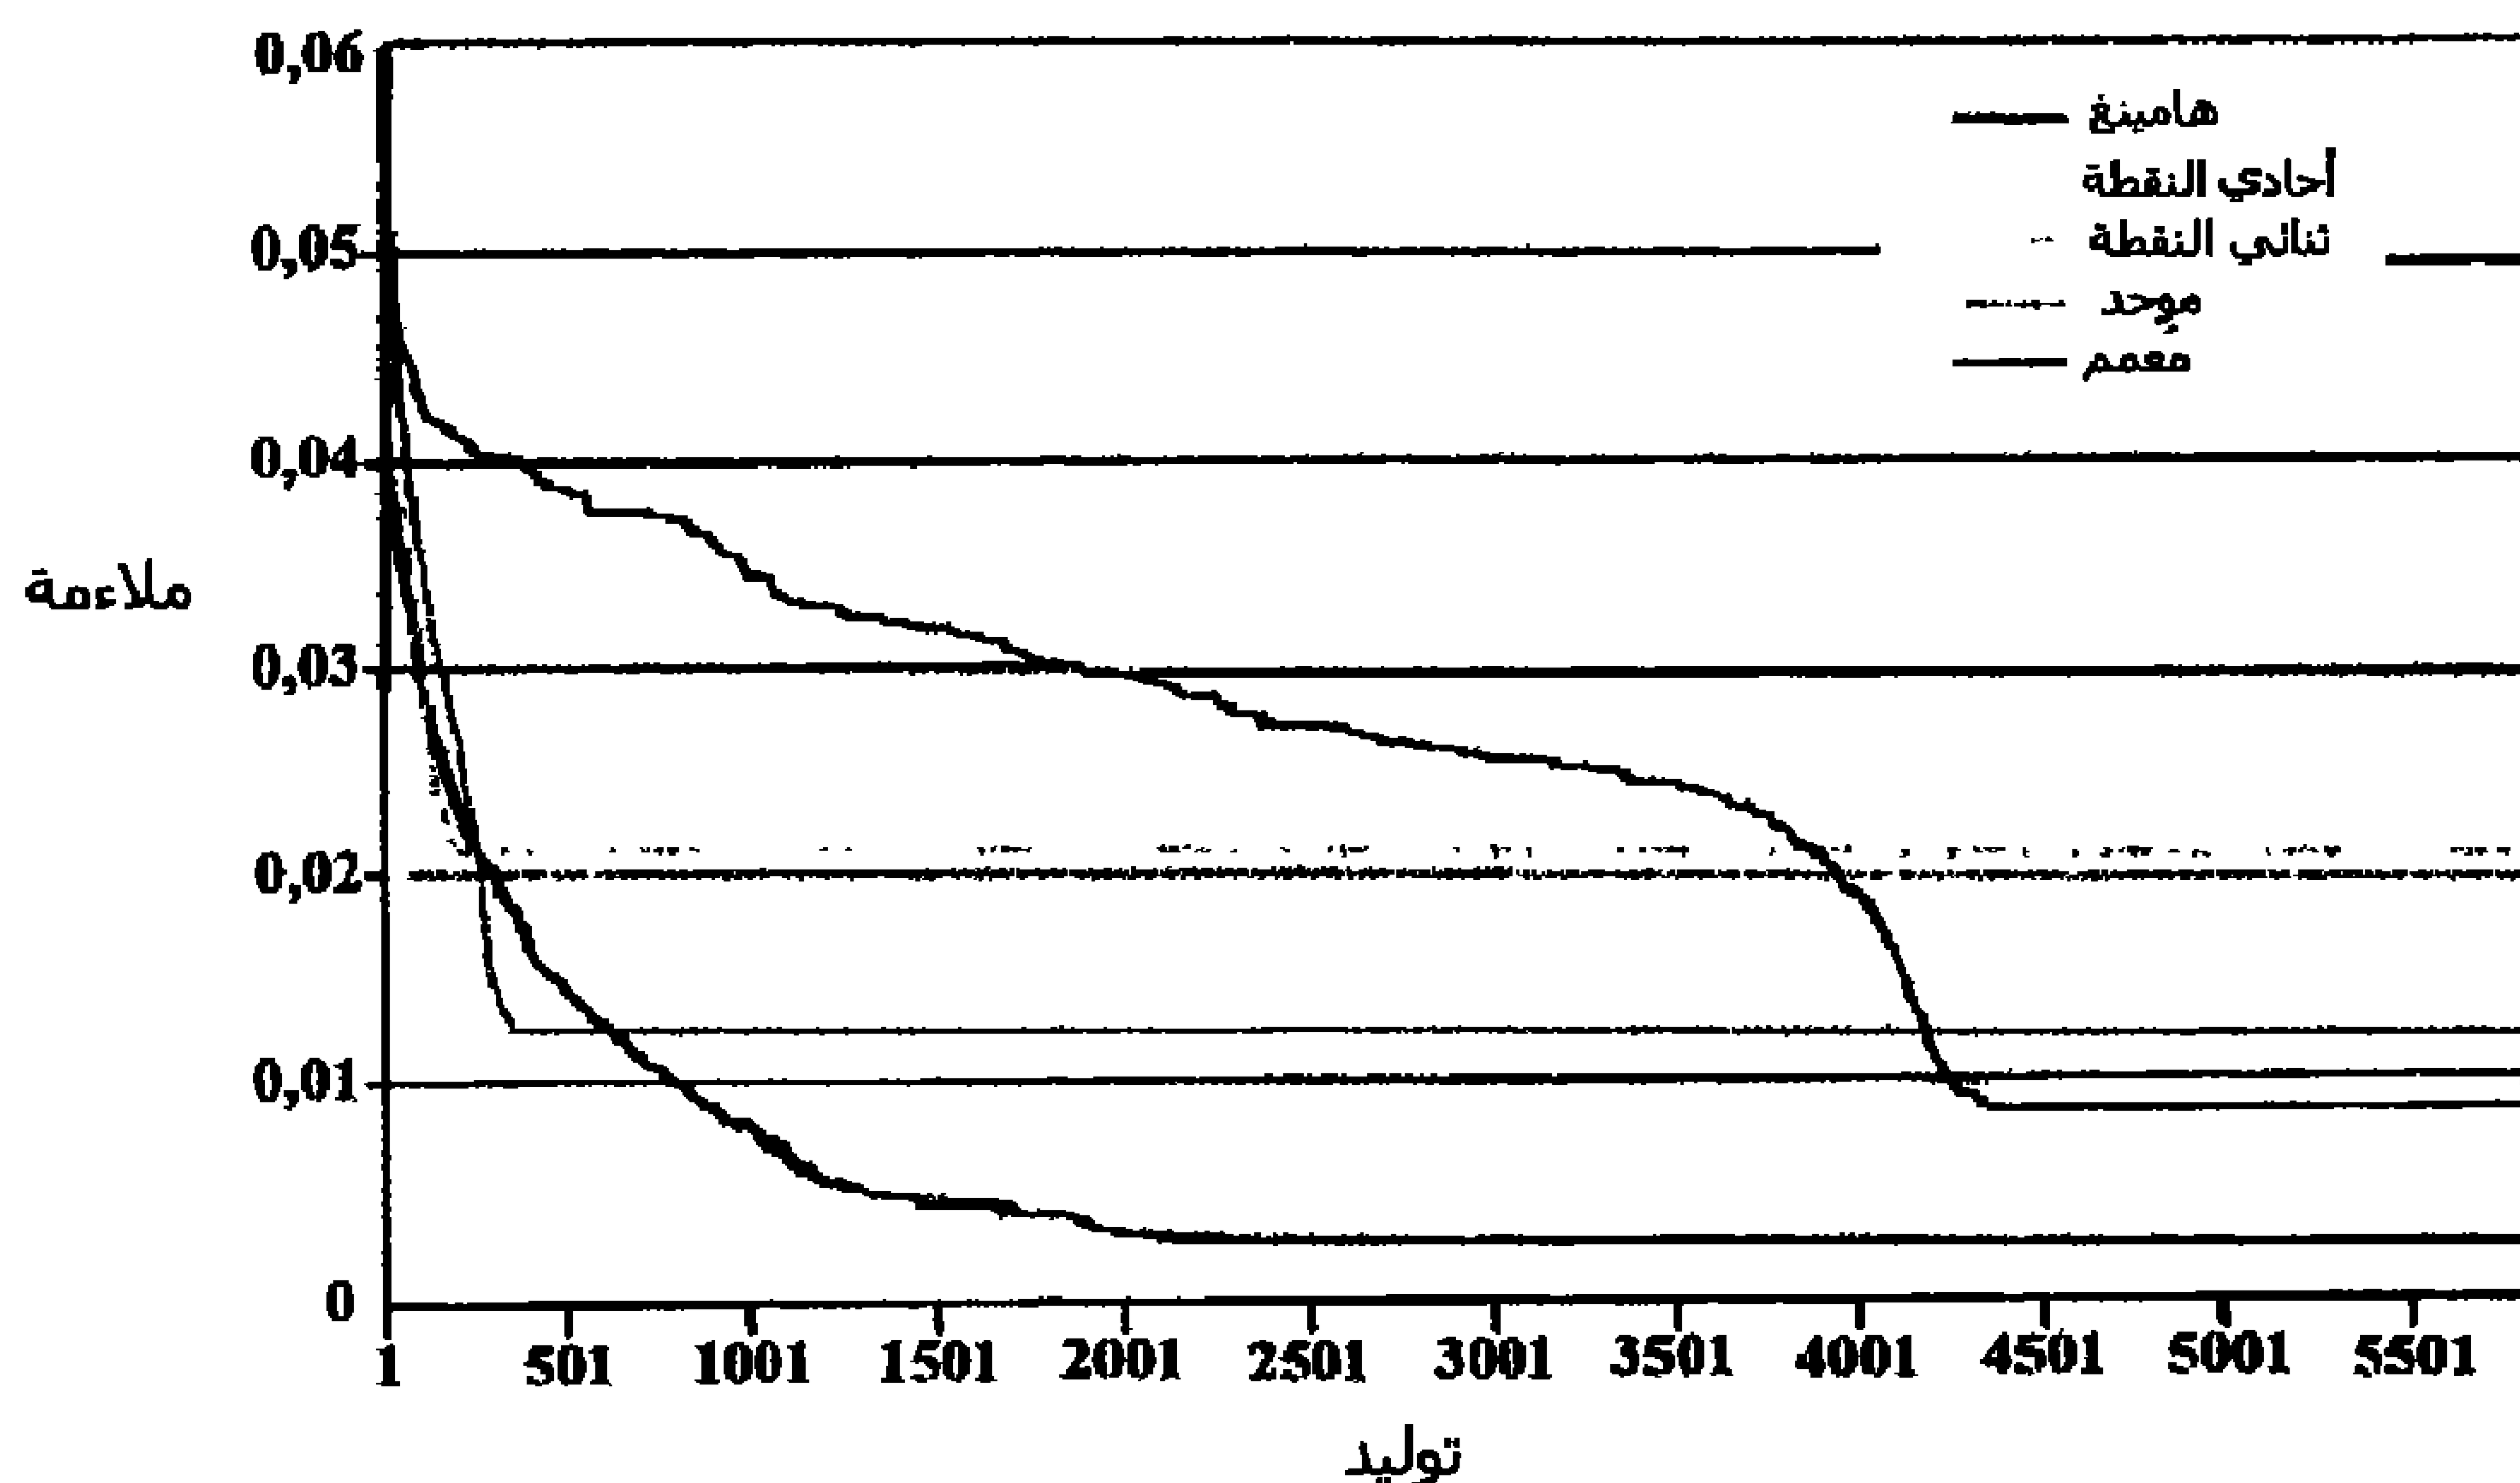
الجدول (2) الحلول النهائية للمشفر/فاك التشفير

	ترميز مباشر	ترميز قواعدي	تصنيف بنى هندسية أساسي
4 - 0 - 4	% 42	% 58	% 74
4 - 1 - 4	% 41	% 32	% 15
4 - 2 - 4	% 17	% 10	% 11

يمكن أن يستخدم معامل تصالب هامينغ في GA الثنائية (الشكل 1) لتصميم بنى هندسية عصبونية، وهو يزيد سرعة التقارب ويجعل الوقوع في القيمة المثلى المحلية أقل من المحتمل نسبةً إلى معاملات التصالب الأخرى عند استخدام تصنيف بنى هندسية أساسي.

النتائج الاختيارية لحل مسألة المشفر/فاك التشفير مبينة بترميز بنى هندسية مؤلفة بحد أعلى من أربع وحدات دخل وخرج وحتى ثمانية عصبونات خفية. البارامترات الوراثية مماثلة لتلك المستخدمة سابقاً. يبين (الشكل 9) عملية التقارب لــ GA الثنائية نحو الشبكة العصبونية المثلى باستخدام معاملات تصالب هامينغ، والمعامل أحادي النقطة، وثنائي النقطة، والموحد، والمعمم. من أجل كل معامل، رُسم معدل الملاءمة بعد 000 50 تكرار تعلّم للسلاسل الثنائية العشرة الأفضل من المجتمع مقابل التوليد.

الشكل (9) *عملية التقارب في مسألة المشفر/فاك التشفير*



يدرج (الجدول 3) ناتج الشبكات العصبونية لحل مسألة المشفر/فاك التشفير من قبل كل معامل من معاملات التصالب الخمسة المستخدمة مع طريقة تصنيف البنى الهندسية الأساسية. ومن الواضح أن معامل هامينغ يفوق المعاملات البقية أداءً. أنتجت 84 % من التنفيذات بمعامل هامينغ الشبكات العصبونية 4 - 0 - 4 و4 - 1 - 4. إن التصالب المعمم – الذي هو ثاني أفضل معامل بعد معامل هامينغ – يحصل على أفضل بنيتين هندسيتين في 68 % من الحالات.

الجدول (3) الحلول النهائية للمشفر/فاك التشفير لكل من معاملات التصالب الثنائية

	هامينغ	أحادي النقطة	ثنائي النقطة	موحد	مُعمم
4 - 0 - 4	% 74	% 0	% 0	% 0	% 38
4 - 1 - 4	% 15	% 0	% 0	% 0	% 30
4 - 2 - 4	% 11	% 0	% 0	% 6	% 18
4 - 3 - 4	% 0	% 0	% 0	% 13	% 12
4 - 4 - 4	% 0	% 19	% 23	% 26	% 2
أخرى	% 0	% 81	% 77	% 55	% 0

من النتائج المحققة والاعتبارات النظرية الموصوفة سابقاً، نختار تصنيف البنى الهندسية الأساسية مع معامل تصالب هامينغ كـ GA ثنائية لبناء البنى الهندسية العصبونية لإنشاء النظام التطوري من أجل تصميم وتدريب شبكات عصبونية أمامية الانتشار. تُدرب ANN للحصول على ملاءمتها باستخدام GA مرمزة بأعداد حقيقية، تستخدم التصالب المورفولوجي.

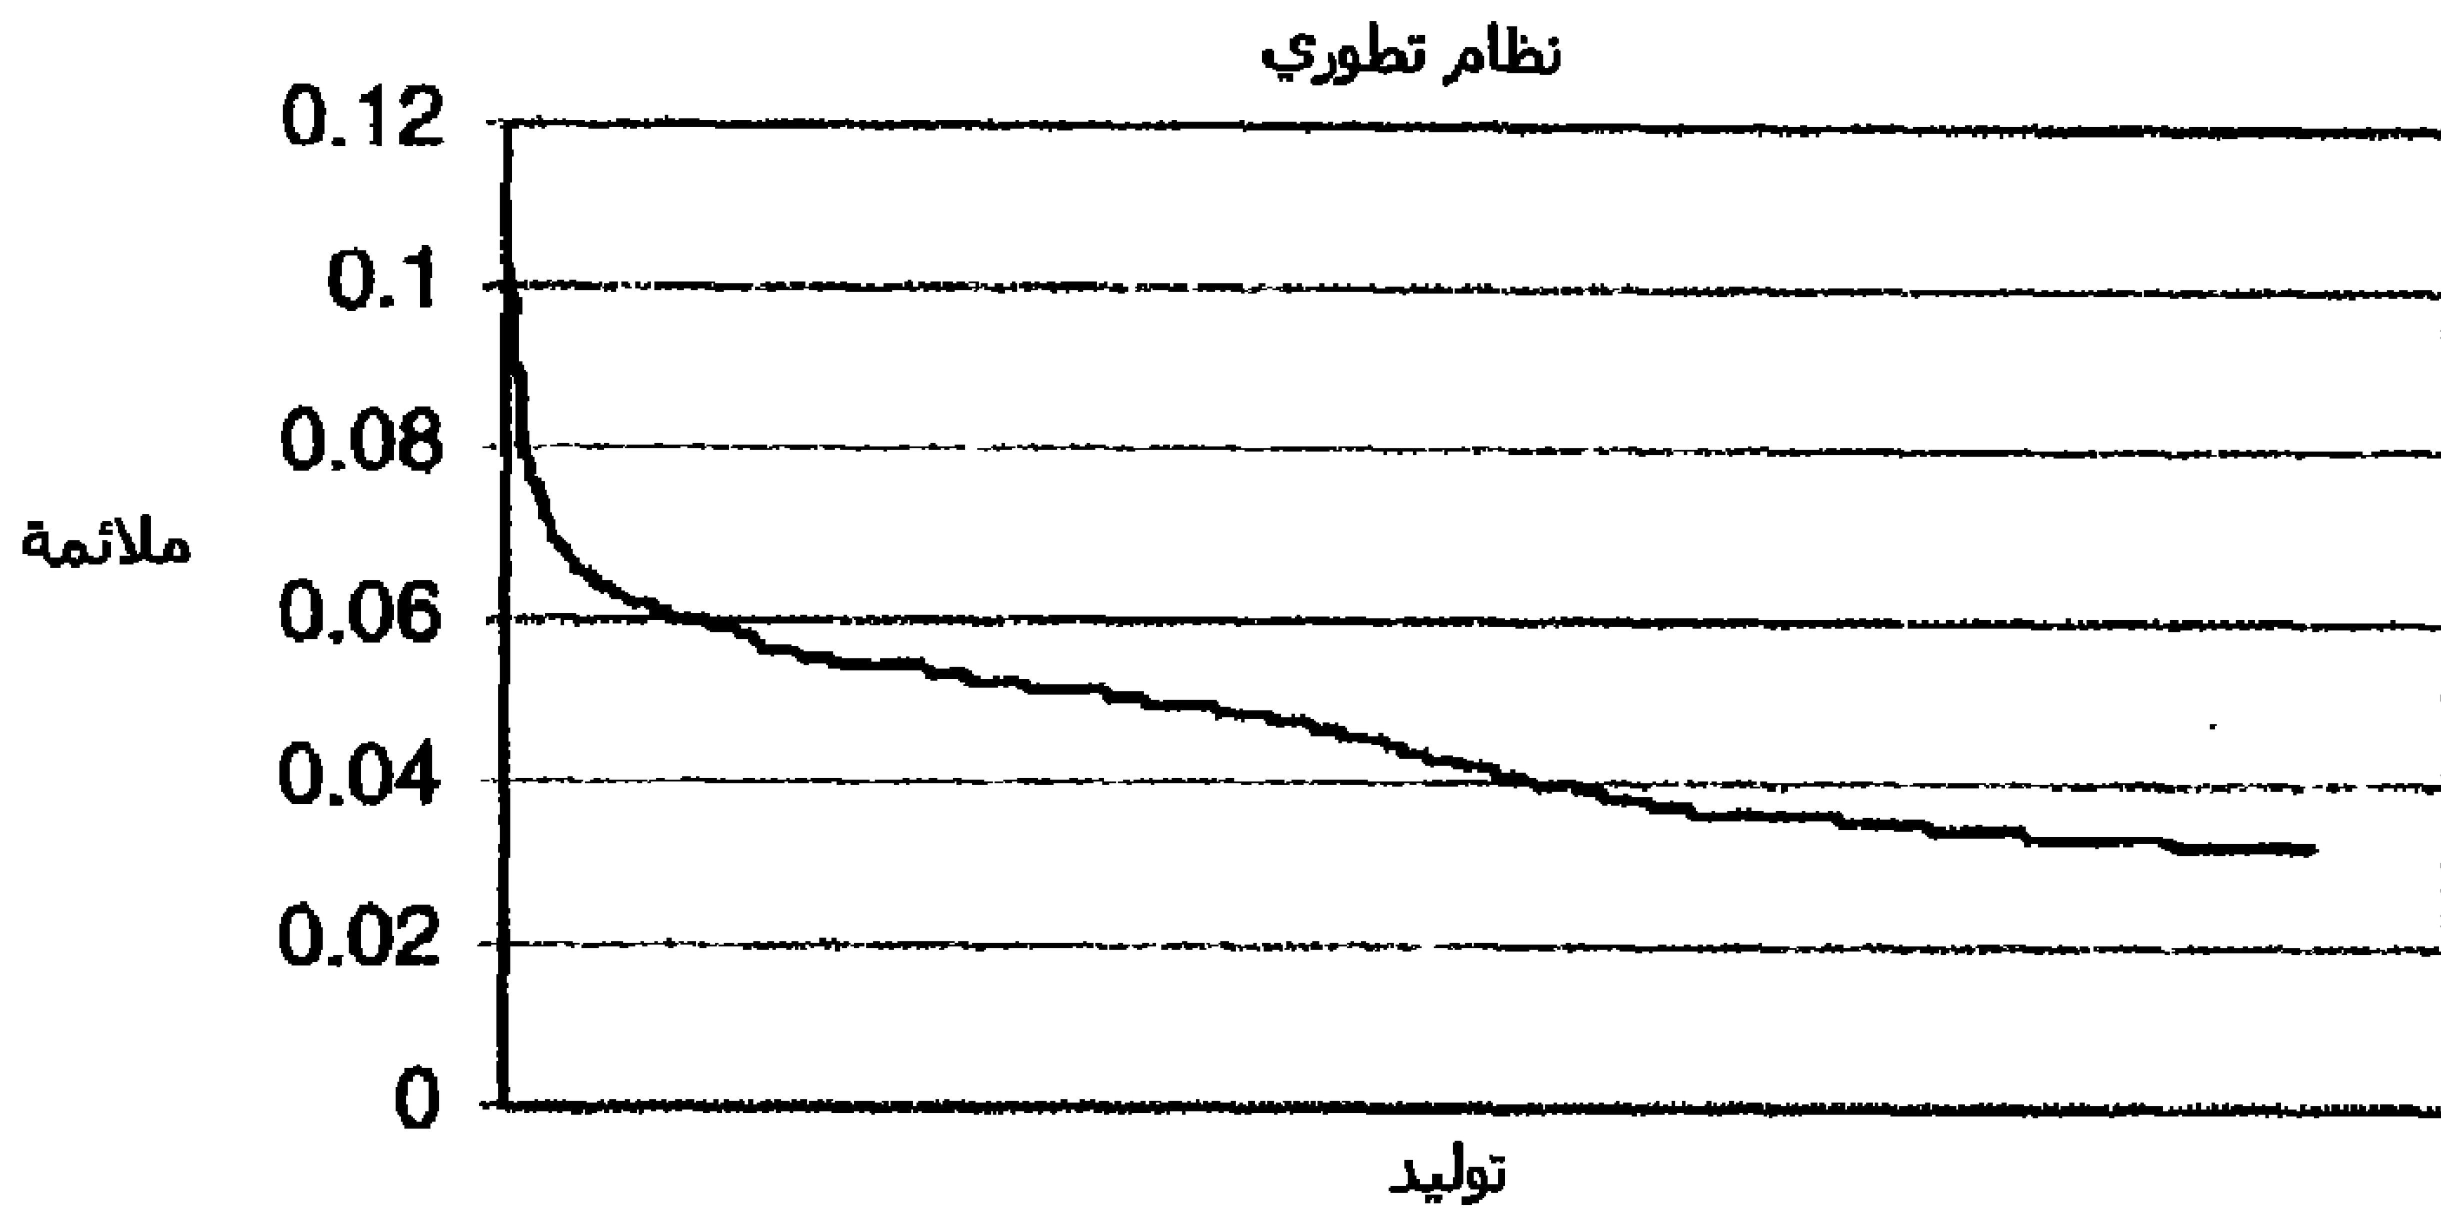
تطبيق: تشخيص سرطان الثدي

طُبق تشكيل النظام التطوري المختار في القسم السابق على مسألة من الواقع الحقيقي وهي: تشخيص الكتل المريبة الموجودة في نسيج الثدي، التي يمكن أن تكون ورماً سرطانياً. هذا التطبيق هو جزء من مشروع أكبر لكشف وتشخيص الأمراض الصدرية آلياً. المدخل لبناء النظام حتى الآن هو مجموعة كاملة من مناظر ماموغرامات mammograms (صور شعاعية) مرقمنة من صدور مرضى، تستخدم للبحث عن التكلسات الميكروية والكتل المريبة التي تمثل الحالتين الشاذتين الواجب كشفهما بالماموغراف (بفحص الصور الشعاعي). هناك منظومتان فرعيتان تعملان بالتوازي، منظومة فرعية لكشف التكلسات الميكروية، ومنظومة فرعية لكشف الكتل. ويكون الخرج عبارة عن مجموعة من الخصائص لكل حالة شاذة مكتشفة. سنركز هنا على المجموعة الجزئية لكشف الكتل. يتألف الخرج الذي تعطيه هذه المنظومة الفرعية لكل كتلة مُكتشفة من شعاع بـ 10 قيم حقيقية: القيمة الأولى هي نصف قطر الكتلة (متوسط المسافات من المركز إلى نقاط محيطية)، النسيج (الانحراف المعياري لقيم المقياس الرمادي)، المحيط، المساحة، الادماجية (التراصية) (مربع المحيط/المساحة – 1)، التقعر (شدة الأجزاء المقعرة من الكنتور)، تناظر الكتلة، الانحراف المعياري للمسافات المأخوذة من مركز الكتلة إلى المحيط، المسافة الأكبر، والجزء الأكثر تقعراً من المحيط. أُختيرت هذه السمات بعد إجراء عدة جلسات مقابلة مع أخصائيي الأشعة الخبراء العاملين على المشروع.

يأخذ النظام التطوري مجموعة تدريب من 330 نمطاً مع 10 مدخلات ذات قيم حقيقية (مدخل واحد لكل خاصية للكتلة)، وخرج واحد بقيمتين محتملتين: 1- إذا أُعتبرت الكتلة حميدة، و1+ إذا اعتبرت الكتلة خبيثة. يجب أن يعطي النظام العصبوني الذكي ANN الصغرى المدربة لحل هذه المسألة. أُعطيت النتائج المقدمة من قبل النظام التطوري فيما يخص سرعة التقارب وحجم الشبكات العصبونية الناتجة. البارامترات الوراثية المستخدمة هي نفسها الموجودة في القسم السابق. (يبين الشكل 10) التقدم المنجز من قبل النظام التطوري بتقارب نحو الشبكة العصبونية المُثلى. رُسمت قيم الملاءمة لأفضل عشرة سلاسل ثنائية من المجتمع مقابل التوليد. وتم ترميز بنى هندسية بحد أعلى من 10 وحدات دخل وخرج واحد وحتى 100 خلية عصبونية خفية. هذا يعني – في حالة تصنيف البنى الهندسية الأساسية – بأن طول السلسلة الثنائية هو حوالي 1000 بت.

يظهر (الجدول 4) عدد اتصالات الشبكات العصبونية الناتجة من أجل 100 تنفيذ اختبار. في السطر الثالث من هذا الجدول، يمثل المجال [30 - 25] الشبكات العصبونية الناتجة التي لديها بين 25 و30 اتصال. الأداء العالي وجودة الحلول الناتجة بالنظام التطوري المقترح واضحة جداً من هذه التجربة.

الشكل (10) *عملية التقارب للنظام التطوري من أجل تشخيص السرطان*



الجدول (4) عدد الاتصالات لحل الشبكات العصبونية

عدد الاتصالات	نظام تطوري
24	% 62
[25 - 30]	% 31
[31 - 40]	% 7
أكثر من 40	% 0

تمتلك الشبكة العصبونية الصغرى التي تحل هذه المسألة - التي أُنتجت خلال 62 % من محاولات التنفيذ - 24 اتصالاً كما هو مبين في الجدول 4. من المهم ذكر أنه لم تظهر الحاجة إلى الاتصالات المباشرة من الدخل إلى الخرج، وأن النظام التطوري أزال أربعة مداخل. بالتالي، نفذ النظام المقترح تحليل حساسية للمسألة مزيلاً كافة المتغيرات التي ليس لها أهمية أو ذات أهمية صغيرة جداً للخرج. يدين النظام بهذه الميزة الهامة إلى طريقة تصنيف البنى الهندسية الأساسية.

في هذه الحالة، تكون متغيرات الدخل المزالة هي: المتغير 1 (نصف قطر الكتلة)، المتغير 3 (المحيط)، المتغير 7 (تناظر الكتلة)، وأخيراً المتغير 8 (الانحراف المعياري للمسافات من المركز إلى المحيط). تحمل هذه المتغيرات المحذوفة علاقة واضحة لبعضها البعض: يمثل نصف القطر والمحيط حجم الكتلة، بينما يمثل المتغيران الآخران شكل حواف الكتلة. اتفق أخصائيو الأشعة العاملون على المشروع، بأن حجم كتلة ما ليس وثيق الصلة جداً، على الرغم من أنه أحياناً يعطي معلومات إضافية. لم يزل النظام بشكل كامل المعلومات المتعلقة بحجم الكتلة، لأن المساحة - التي لم تُحذف - هي بديلة عن نصف القطر والمحيط. يُطبق أمر مماثل على المتغيرين المحذوفين الآخرين: التناظر والانحراف المعياري لأنصاف الأقطار، التي يمكن أن تكون معوضة بالتقعر.

أُختبرت الشبكة العصبونية الناتجة باستخدام 240 إلى نمطاً اختبارياً، التي لم تُستخدم لتدريب الشبكة منتجةً معدل خطأ مقداره 3.3 %. تتضمن الـ 240 نمطاً اختبارياً: 180 كتلة خبيثة و60 كتلة حميدة. صنفت الشبكة بشكل خاطئ حالة واحدة فقط من الحالات 180 الخبيثة، بينما كانت الشبكة بسبعة أخطاء فيما يتعلق بالحالات الحميدة. من أجل أخصائيي الأشعة، يجب أن يكون احتمال التصنيف الخاطئ للحالات الخبيثة أقل منه للحالات الحميدة. وذلك لأنه خطير جداً إخبار مريضة بأن الكتلة التي وجدت في نسيج ثديها هي حميدة، بينما هي سرطان بالفعل من الجهة الأخرى.

الاتجاهات المستقبلية

إن التقنيات التطورية المقدمة في هذا الفصل يمكن أن تكون متكيّفة لمعظم البنى الهندسية العصبونية والطبولوجيات الموجودة هذه الأيام، والتي تجعل من الممكن اختيار النموذج العصبوني الأكثر ملاءمةً لنوع المسألة المراد حلها. إن العمل البحثي ضمن الذكاء الصنعي الترابطي مُركّز على نوع محدد من البنى الهندسية العصبونية، التي هي شبكات التوابع الأساسية الشعاعية، والتي هي نوع من الشبكات المفيدة جداً لمسائل تصنيف الأنماط (Yampolskiy, Novikov, & Reznik, 2003). وذلك بسبب – متعددة الطبقات – تأثر خرج شبكة التابع الأساسي الشعاعي على خلاف شبكات Perceptrons بشكل رئيسي بعصبون الطبقة الخفية، الذي يكون مركزه أقرب إلى نمط الدخل، وبالتالي فإن هذه الشبكات العصبونية هي مقاربات محلية، بينما شبكات Perceptrons متعددة الطبقات هي مقاربات شاملة (عامة). بالرغم من محاسن شبكات التوابع الأساسية الشعاعية، فإن تصميم بنية هندسية مثلى لحل مسألة خاصة هو من جديد أبعد ما يكون مسألة بسيطة. إضافة لذلك، فإن شبكات التوابع الأساسية الشعاعية المدربة وفقاً للطرق المعتمدة على هبوط التدرج التقليدي قد أظهرت أنها على الأرجح واقعة في قيمة مُثلى محلية، وهي بالتالي أقل دقة عندما تُطبق هذه الطرق على شبكات Perceptrons متعددة الطبقات. وذلك لأنه يتطلب إيجاد مجموعة أوزان الاتصالات التي تعطي أفضل حل للمسألة، كما يجب أيضاً البحث عن مراكز التوابع الأساسية الشعاعية لعصبونات الطبقة الخفية.

للتغلب على مشكلة الوقوع في قيمة مثلى محلية، ولتحسين دقة نتائج تطبيق الانتشار الخلفي المتدرج على RBFN، تمت إدارة البحث وتوجيهه نحو بناء خوارزميات تدريب هجينة (Cohen & Intrator, 2002). تدمج هذه الخوارزميات البحث غير المُراقب لمراكز عصبونات الطبقة الخفية باستخدام خوارزميات العنقدة Clustering Algorithms كالمعدلات K أو الإصدار المطور – المعدلات المؤثرة K – مع الانتشار الخلفي المتدرج للحصول على أوزان الاتصالات

(Mashor, 2000). على أية حال، ما تزال هذه الطرق مُقلقة بنفس الضعف الشديد للوقوع في قيمة مُثلى محلية. لأنها تستخدم طرق أمْثلة معتمدة على الاشتقاقات. يظهر العمل البحث الآن بأن تطبيق GAs المرمزة بأعداد حقيقية مع تصالب مورفولوجي يتفوق بالأداء على الانتشار الخلفي وخوارزميات التدريب الهجينة لشبكات التوابع الأساسية الشعاعية. وعلى نفس النمط، تم فتح اتجاه بحث جديد وواعد تكون فيه طريقة تصنيف البنى الهندسية الأساسية وتصالب هامينغ متكيّفان لبناء أنظمة ذكية آلياً باستخدام نوع من الشبكات العصبونية تستغل محاسنها من حيث سرعة التقارب والاحتمالية المنخفضة للوقوع في قيمة مُثلى محلية. تتطلع الجهود طويلة الأمد إلى تطوير نظام تطوري قادر على اختيار البنية الهندسية العصبونية الأفضل لمسألة مُعطاة وبناء النظام الذكي الذي يحل هذه المسألة.

الخلاصة

قدم هذا الفصل تقنيات تطورية عديدة من أجل بناء أنظمة ذكية ذاتية التكيّف بشبكات عصبونية أمامية الانتشار، التي تعتبر حالياً أكثر النماذج استخداماً.

من النتائج المذكورة بعد تنفيذ عدة اختبارات، يمكن القول بأن النتائج الأفضل قد أُنتجت بدمج طريقة التصنيف الأساسية مع تصالب هامينغ من أجل GA الثنائية، ومع التصالب المورفولوجي من أجل GA المرمزة بأعداد حقيقية. لا تُرمّز طريقة التصنيف الأساسية بنيات عصبونية غير قانونية، ولذا هي تتطلب طول تصنيف أقصر، لأن فضاء البحث أصغر. الميزة الهامة الأخرى لهذا التصنيف هي أن التغير في بت واحد السلسلة ثنائية يعطي بنية هندسية عصبونية مشابهة جداً. تم تحسين هذه الميزة باستخدام تصالب هامينغ، الذي يُولد نسلاً قريباً جداً من الأسلاف من حيث تعريف مسافة هامينغ، التصالب المورفولوجي قادر بشكل كاف على موازنة الاستكشاف والإمكانيات الاستكشافية لـــ GA المرمزة بأعداد حقيقية، التي تسمح بسرعة بحث عالية، وتتفادى الوقوع في قيمة مُثلى محلية عند ضبط أوزان الاتصالات لشبكة عصبونية ستُدرّب.

إن تطبيق النظام التطوري ضمن تطبيق كامل لحل مسألة حقيقية لاكتشاف وتشخيص الأمراض الصدرية يبين قدرته على إزالة كافة الاتصالات غير المُحتاج لها من أجل الخرج. لذا، يحصل النظام التطوري على بنى هندسية عصبونية أصغر، تقدم تعميماً أعلى وسرعة استجابة وزمن تشغيل أقل.

المراجع

Barrios, D., Carrascal, A., Manrique, D., & Ríos, J. (2000). Neural network training using real-coded genetic algorithms. Proceedings of V Ibero American Symposium on Pattern Recognition, Lisboa, Portugal (pp. 337-346).

Barrios, D., Carrascal, A., Manrique, D., & Ríos, J. (2003). Cooperative binary-real coded genetic algorithms for generating and adapting artificial neural networks. Neural Computing and Applications, L 2(2), 49-60.

Barrios, D., Manrique, D., Plaza, M.R., & Ríos, J.(2001). An algebraic model for generating and adapting neural networks by means of optimization methods. Annals of Mathematics and Artificial Intelligence, 33, 93-111.

Bornholdt, S., & Graudenz, D. (1992). General asymmetric neural networks and structure design by genetic algorithms. Neural Networks, 5, 327-334.

Brown, A.D., & Card, H.C. (2000). Cooperative coevolution of neural representations. International Journal of Neural Systems, 10(4), 311-320.

Carrascal, A., Manrique, D., Ríos, J., & Rossi, C. (2003). Evolutionary local search of fuzzy rules through a novel neuro-fuzzy encoding method. Evolutionary Computation, 11(4), 439-461.

Cohen S., & Intrator, N. (2002). A hybrid projection-based and radial basis function architecture: Initial values and global optimization. Pattern Analysis and Applications, 5(2), 113-120.

D'alotto, L.A., & Giardina, C.R. (1998). A unified signal algebra approach to two-dimensional parallel digital signal processing. New York: Marcel Dekker.

Dai, H., & McBeth,C.(1997). Effects of learning parameters on learning procedure and performance of a BPW. Neural Networks, 10(8), 1505-1521.

Eshelman, L.J..& Schaffer, J. D. (1993). Real-coded genetic algorithms and interval-schemata. Foundations of Genetic Algorithms, 2, 187-202.

Hussain, T.S., & Browse, R.A. (1998). Including control architecture in attribute grammar specifications of feedforward neural networks. Proceedings of the 1998 Joint Conference on Information Sciences: 2nd International Workshop on Frontiers in Evolutionary Algorithms (vol. 2, pp. 432-436).

Hussain, R.A. (2000). Evolving neural networks using attribute grammars. IEEE Sympo sium on Combinations of Evolutionary Computation and Neural Networks, San Antonio, TX (pp. 37-42).

Kitano, H. (1994). Neurogenetic learning: An integrated meted of designing and training neural networks using genetic algorithms. Physica D., 75, 225-238.

Konar, A. (2000). Artificial intelligence and soft computing. Boca Raton, FL: CRC Press.

Manrique, D. (2001). Neural networks design and new optimization methods by genetic algorithms. Ph.D. thesis, Universidad Politécnica de Madrid, Spain.

Mashor, M.Y.(2000). Hybrid training algorithms for RBF network. International Journal of the Computer, 8(2), 50-65.

Michalewicz, Z. (1999). Genetic algorithms + data structures = evolution programs. New York: Springer-Verlag.

Ono,I.,& Kobayashi, S. (1997). A real-coded genetic algorithm for function optimization using unimodal normal distribution crossover. Proceedings of the 7th International Conference on Genetic Algorithms, East Lansing, MI (pp. 246-253).

Principe, J.C., Euliano, N.R., & Lefebvre, W.C. (2000). Neural and adaptive systems, fundamentals through simulations. New York: Wiley & Sons.

Radcliffe, N.J. (1990). Genetic neural networks on MIMD computers. Ph.D. thesis, University of Edinburgh, UK.

Ríos, J., Barrios, D., Carrascal, A., & Manrique, D. (2001). ADANNET: Automatic design of artificial neural networks by evolutionary techniques. Proceedings of the 21st SGES International Conference on Knowledge Based Systems and Applied Artificial Intelligence, Brighton, UK (pp. 67-80).

Siddiqi, A., & Lucas, S.(1998). A comparison of matrix rewriting versus direct encoding for evolving neural networks. Proceedings of the 1998 IEEE International Conference on Evolutionary Computation, Piscataway, NJ (pp. 392-397).

Syswerda, G. (1991). Schedule optimization using genetic algorithms. Handbook of genetic algorithms. New York: Van Nostrand Reinhold.

Yampolskiy, R., Novikov, D., & Reznik, L. (2003). Experimental study of the neural networks for character recognition. Rochester, NY: Department of Computer Science, Rochester Institute of Technology.

الفصل السادس

استخدام البرمجة الوراثية لاستخلاص المعرفة من الشبكات العصبونية الصنعية

ملخص

يتم في هذا الفصل وصف تقنية تجعل من الممكن استخلاص المعرفة المحتواة في ANN مدربة سابقاً. وهذا ما يجعل من الممكن استخدام هذه الشبكات في عدد من المجالات (كالمجال الطبي)، حيث يكون من الضروري معرفة كيفية عملها، بالإضافة إلى امتلاك شبكة لتلك الوظائف. يشرح هذا الفصل كيف تُنفذ هذه العملية لاستخلاص المعرفة المُعرَّفة كقواعد، ووضع تأكيد خاص على استخلاص المعرفة من شبكات عصبونية تكرارية، وبشكل خاص عندما طُبقت في تنبؤ السلاسل الزمنية.

مقدمة

أثناء استخدام ANNs تم الحصول على نتائج مقبولة في المجالات الأكثر تنوعاً من التطبيقات متضمنةً تصنيف الأمثلة، والتعرف على الصور، ومعالجة اللغات الطبيعية.

على أية حال، في بعض المجالات مازال هناك بعض التحفظات على استخدامها وبشكل رئيسي كنتيجة لقضيةٍ وحيدة، هي أنها لا تثبت أهلية استجابتها. تستخلص ANN المعلومات من سلسلة تدريب (مُشكّلة بأزواج دخل - خرج، أو بإدخال بسيط إذا استُخدم تدريب غير مُراقب). اعتماداً على المعلومات المكتسبة يكون من الممكن إنتاج خرج لدخل لم يتواجد سابقاً خلال عملية التعلّم. حتى وإن كانت الاستجابة المزودة صحيحة، فإن ANN لا تزود أية معلومات حول سؤال مفاده: لماذا تم اختيار حل معين بعينه، فهي تتصرف كصندوق أسود. وهذا الأمر غير مقبول في بعض المجالات، على سبيل المثال: أي نظام مستخدم في التشخيص الطبي يجب ألا يتوصل إلى استنتاجات صحيحة وحسب، بل يجب أن يكون أيضاً قادراً على تبرير على ماذا قد استند بقراره. لهذا السبب، تُستخدم النظم الخبيرة بشكل شائع في الطب.

إن النظم الخبيرة Expert Systems (ES) قادرة على شرح الحل أو الاستجابة المنجزة، التي هي جوهرها الرئيس، كما أنها أيضاً ضمان نجاحها. لذا، يحاول هذا الفصل تطوير نظام يقوم بتنفيذ استخلاص آلي للقواعد من ANN مدربة سابقاً، واكتساب المعرفة التي حصلت عليها ANN من المسألة التي تحلها.

حتى تاريخه استخدمت تقنيات مختلفة لاستخلاص القواعد من خلال ANN وتطبق دائماً على ANN متعددة الطبقات، باعتبار أنها أسهل في التعامل. تمتلك هذه الشبكات أيضاً قدرة استيعاب محدودة فيما يخص المعرفة التي يمكن أن تكون موزعة في اتصالاتها.

يمكن استنتاج، أن استخلاص القواعد والتعابير من ANN تكرارية يكون أكثر تعقيداً، بسبب حقيقة أن الحالات الماضية تتدخل في التفعيل العصبوني، وأن قدرة استيعاب معرفتها الموزعة أعلى على نحو كبير من تلك التي تخص ANN متعددة الطبقات، باعتبار أنه لا توجد قيود على الاتصالية العصبونية. إضافة إلى ذلك، إذا ما استُخدمت ANNs تكرارية في مسائل ديناميكية، حيث تتحلل بعض المواصفات الزمنية كتنبؤ لسلاسل الزمنية، فإن مهمة الاستخلاص باستخدام الطرق المطورة تصبح أصعب بكثير إن لم تكن مستحيلة.

على أية حال، إذا أعطت ANN نتائج جيدة، لماذا يتم رفضها؟. سيكون كافياً إيجاد طريقة تثبت أهلية الخرج المُعطى من قبل ANN بالاعتماد على قيم الدخل. يجب أن تكون هذه الطريقة قابلة للتطبيق على شبكات من أي نوع، وهذا يعني بأن عليها أن تستجيب للخصائص التالية (Tickle, 1998):

- **استقلالية البنية الهندسية:** يجب أن تكون طريقة استخلاص القواعد قادرة على أن تُطبق بشكل مستقل عن البنية الهندسية لـــ ANN بما في ذلك البنى الهندسية التكرارية.
- **استقلالية خوارزمية التدريب:** لا يمكن أن يعتمد استخلاص القواعد على الخوارزمية المستخدمة من أجل عملية تعلّم ANN.
- **التصحيح:** تخلق العديد من طرق استخلاص القواعد تقريبات للأداء الوظيفي لـــ ANN فقط بدلاً من خلق قواعد دقيقة قدر الإمكان.
- **البلاغة:** يجب أن تمثل اللغة المستخدمة لوصف القواعد المستخلصة المعرفة المكتسبة من ANN بشكل بليغ قدر الإمكان.

البرمجة الوراثية

يعتقد البعض بأن العالمين Cramer (1985) و Fujiki (1987) اللذين نشرا مقالات عن تطور البرامج في عام 1985م وعام 1987م في مؤتمر ICGA الأول – هما رواد البرمجة الوراثية (GP). مع

ذلك، يظن آخرون بأن العالم Friedberg، والذي طوّر منذ عام 1958 وحتى عام 1959م برامج لغة الآلة (Friedberg, 1958; Friedberg 1989)، هو حقاً الرائد في هذا المجال.

ابتكر العالم John Koza (1992) المصطلح المستخدم كعنوان لكتابه (Genetic Programming). يرسي هذا الكتاب بشكل منهجي الأساس لـ GP المستخدمة في الوقت الحاضر. لاحقاً، نشر نفس المؤلف كتاباً بعنوان Genetic Programming I (Koza, 1994)، وحالياً الكتاب Genetic Programming III (Koza, 1999). وكلاهما يستكشف الإمكانيات الجديدة لـ GP.

اشتُقت مجالات مختلفة من GP. واحد من أكثر المجالات الواعدة فيما يتعلق باكتشاف المعرفة Knowledge Discovery (KD) هو مجال القواعد الغامضة (Fuzzy rules) (Fayaad, 1996، bonarini, 1996). يُشتق هذا المجال من اتحاد بين المنطق الغامض والأنظمة المعتمدة على القواعد (SBR). يمكن أن يتم الحصول على القواعد الغامضة من خلال الحوسبة التطورية (EC) مع تقنية معروفة كالتوابع المُعرّفة آلياً (ADF) (Koza, 1994)، وتطور المفهوم المعروف بـ "البرمجة الوراثية الكلاسيكية".

تعمل GP خلال تطور المجتمع. في هذا المجتمع، تكون كل سلسلة فردية هي حل للمسألة التي نُحاول حلها. يحدث هذا التطور باختيار السلاسل الفردية الأفضل (على الرغم من أن السلاسل الفردية الأسوأ أيضاً لديها احتمال صغير لتكون مختارة) ودمجها لخلق حلول جديدة. تُنفذ هذه العملية باستخدام خوارزمية الانتقاء، والطفرة، والتصالب. بعد بضعة توليدات، يُتوقع أن يحتوي المجتمع على حل جيد بما فيه الكفاية للمسألة.

في GP، يُنفذ تصنيف الحلول في هيئة أشجار "Trees". كنتيجة، يجب على المستخدم أن يحدد ما هي الطرفيات "الأوراق" والتوابع التي يمكن أن تستخدم من قبل الخوارزمية. هنا يمكن أن تُنتج تعابير معقدة، تكون إما رياضية (تتضمن معاملات حسابية)، أو منطقية (تتضمن معاملات رابطية أو منطقية)، أو قد تكون أكثر تعقيداً.

استخلاص قواعد ANN

إن استخلاص القواعد التي تمثل المعرفة المخزنة في ANN هي مسألة NP كاملة. على أية حال، لم يشكل ذلك عائقاً لتطوير عدد كبير من الأنظمة، التي تنفذ هذه المهمة بنجاح تقريباً (Rabuñal, 2004).

ميّز العالم Andrews (1995, 1996) ثلاث تقنيات لاكتشاف القواعد: فك تركيبية "decompositional"، وتعليمية "pedagogical"، وانتقائية "eclectic". يتصل الأول باكتشاف في المستوى العصبوني مركزاً على التعامل مع كلٍ من عصبونات ANNs. وبشكل خاص، تلك الموجودة في الطبقة الخفية وطبقة الخرج. وبالتالي، تُستخلص القواعد من كل عصبون وعلاقته بالعصبونات

الأخرى. وهذا ما يجعل الطرق المتعلقة بهذه التقنية معتمدة كلياً على البنية الهندسية لـــ ANN التي ستتعامل معها. الأمر الذي يعني بأن قابليتها التطبيقية تكون محدودة بشكل عام. تعامل التقنية الثانية ANN كصندوق أسود، حيث بتطبيق المدخلات تُحلل فقط العلاقات بين المدخلات ومخرجات ANN. الغرض الرئيس من هذه التقنية هو الحصول على التابع الذي يُحسب من قبل ANN. تستخدم التقنية الثالثة البنية الهندسية لـــ ANN وأزواج الدخل – الخرج كتتمة لخوارزمية تدريب رمزية.

يمكن أن تُدمج تقنيتا استخلاص القواعد "فك التركيبة" و"التعليمية". ومثال ذلك DEDEC (Tickle, 1996)، الذي يستخدم ANN مدربة لخلق أمثلة، تُستخلص منها القواعد التحتية. على أية حال، يكون الاختلاف الهام بأنها تستخلص معلومات إضافية من ANN مدربة بإخضاع أشعة الأوزان الناتجة إلى تحليل إضافي (طريقة فك تركيبية جزيئية). تُستخدم هذه المعلومات بعد ذلك لتوجيه الاستراتيجية من أجل توليد مجموعة صغرى من الأمثلة لطور التعلّم، وهي أيضاً تستخدم خوارزمية فعالية لطور استخلاص القواعد.

يتضمن Rabuñal (2004) مقدمة للتقنيات الأكثر أهمية من أجل استخلاص القواعد من الشبكات العصبونية. يناقش Rabuñal (2004) طرقاً مثل: الطرق الموصوفة في Jang (1992)، Buckley (1993)، و Benítez (1997) التي تستخدم القواعد المستفيضة، و Towell (1994) الذي حلّل الاتصالات الشبكية، وباستخدام البرمجة الخطية أو المباشرة كما في Thrun (1995)، وGA كما في Keedwell (2000)، وخوارزميات أخرى مثل RULENEG (POP, 1994)، وTREPAN (Craven, 19964, 19966)، وطرقاً أخرى معتمد عليها (Chalup, 1998; Visser, 1996). إحدى أكثر السمات الرائعة في كل عملية اكتشاف هي أَمْثَلة القواعد المكتسبة من تحليل ANN. يجب ملاحظة أن القواعد المكتشفة قد يكون لها شروط فائضة. ويمكن أن تحتوي العديد من القواعد المعينة في شبكات عامة، والعديد من التعابير المنطقية التي اُكتشفت يمكنها أن تُبسط، إذا تمت كتابتها بطريقة أخرى. وبالتالي، تشمل أَمْثَلة القواعد على تبسيط وإسهاب العمليات الرمزية بالقواعد. اعتماداً على طريقة الاكتشاف ونوع القواعد التي تم الحصول عليها، يمكن أن تُطبق تقنيات أَمْثَلَة مختلفة. وبالتالي، يمكن تصنيفها إلى مجموعتين رئيسيتين: طرق استدلالية Posteriori وطرق أَمْثَلَة ضمنية. تتألف المجموعة الأولى عادةً من خوارزمية تحليل تركيبي، تُطبق على القواعد المكتشفة بغية تبسيطها. على سبيل المثال، يستخدم Duch (2001) لغة Prolog كلغة برمجة بغية تنفيذ معالجة عليا للقواعد المكتسبة. بهذه الطريقة، تُحقق المتغيرات اللغوية المُثلى، التي تساعد في اكتشاف القواعد المُبسطة التي تستخدمها هذه المتغيرات. إن طرق الأَمْثَلة الضمنية هي تقنيات مستخدمة في خوارزميات اكتشاف القواعد، تجعل الخوارزمية تنتج قواعداً أفضل وأفضل.

أنظمة استخلاص المعرفة

مقدمات تطويرية

عند الاصطدام بتصميم خوارزمية اكتشاف، فإن المهمة الأكثر أهمية هي تقرير طريقة عملها. وكما شُرح سابقاً، يمكن أن تُصنف تقنيات الاكتشاف في ثلاث مجموعات رئيسية: "فك تركيبية" و"تعليمية" و"انتقائية".

في الطريقة التعليمية، تُخلّق القواعد اعتماداً على تحليل تجريبي للأزواج (دخل – خرج) المُقدّمة إلى ANN. وهذا تقريب معتمد على الصندوق الأسود، طالما أنه يتجاهل كلياً الأداء الوظيفي الداخلي لــ ANN. تشمل الفكرة الأساسية على النظر إلى عملية استخلاص القواعد كمهمة تعلّم، يكون فيها البحث عن الفكرة العامة هو التابع المحسوب بواسطة ANN، وخصائص الدخل هي مدخلات لــ ANN. تحاول تقنيات هذا النوع استخلاص القواعد، التي تحول بشكل مباشر هذه المدخلات إلى مخرجات. على نقيض ذلك – في طريقة فك التركيب – تُحدد القواعد بفحص الوزن لكلّ من عصبونات ANN، والعلاقة بين عصبون واحد والبقية. تمتلك هذه التقنية عدة عوائق. أولاً، بالتحليل المستقل للعقد، فإن النتائج تعتمد كلياً على البنية الهندسية لــ ANN المُحللّة. يزداد تعقيد استخلاص القواعد بشكل أسي، عندما يزداد حجم ANN، الأمر الذي يعني بأن تقنيات هذا النوع غير صالحة للاستخدام مع ANN معقدة.

تمزج الطريقة الثالثة (الانتقائية عناصر من الطريقتين السابقتين معاً. في هذه الفئة، قد تُصنّف التقنيات التي تستخدم معرفة البنية الهندسية الداخلية أو أشعة أوزان ANN لإكمال خوارزمية التعلّم.

أظهرت توليفة تقنيات CE مع خوارزميات حثية تقليدية أنها قادرة على تقديم نتائج أفضل من تلك الناتجة بتطبيق التقنيات السابقة على أساس السلاسل الفردية. على أية حال، يخفض تطبيق الخوارزميات التطويرية على السلاسل الفردية من تعقيد طريقة استخلاص القواعد، ويعطي نتائج جيدة بالتساوي مع تلك التي يمكن أن يُحصل عليها بتوليفات من الطرق الأخرى. ومثال ذلك النظام GABIL، الذي ينفذ بحثاً تزايدياً لمجموعة من قواعد التصنيف الممثلة بسلسلة من خانات (بتات) ثابتة الطول.

إن تطبيق تقنيات CE مماثل لمدى معين من تطبيق ANN لحل المسائل. ويعتمد كلاهما على تفسير عمليات البيولوجية. وهي تقنيات موصى بها جداً عند العمل على المسائل ذات عدد المتغيرات الذي تنمو بشكل أسي في هذه الحالات (ما يجعلها غير فعالة لتطبيق عمليات بحث حتمية) فهي تتصرف بكفاءة عالية.

بين تقنيات CE، يطرح اختيار GA كخوارزمية استخلاص قواعد سلسلة من الصعوبات. تكمن أهم تلك الصعوبات في أنه لتخزين القواعد المستخلصة في الصبغي من الضروري استخدام GA بسلاسل فردية متغيرة الطول، طالما أنه من غير الممكن بشكل مسبق تعيين عدد القواعد التي ستستخلص، الأمر الذي يزيد إلى حد كبير التعقيد المتضمن. علاوة على ذلك، فإن تصنيف مسألة استخلاص القواعد كسلسلة مفهومة وقابلة للتفسير هي مهمة عالية التعقيد.

حُلَّ عدد كبير من هذه الصعوبات بواسطة GP. أولاً، لا يُحدد مسبقاً تصنيف الحلول كشجرة حجم ثابت للحل، أو عدد معين من القواعد. علاوة على ذلك، فإن الشجرة هي طريقة تقليدية للتمثيل المستخدم من قبل محللين لغويين ونحويين تستخدم دائماً لتحليل البرامج، والتي يمكن أن ينظر لها كتعميم للقواعد المستخلصة من ANN. لهذه الأسباب اُختيرت GP لتستخدم كخوارزمية حثية لاستخلاص القواعد.

في هذه المقالة، تُستخدم GP كخوارزمية لبناء الأشجار التركيبية التي تمثل القواعد. وللقيام بذلك، تم استخدام عملية ارتداد طُبقت على أنماط دخل - خرج. أنماط الدخل هي سلاسل دخل مطبقة على ANN. أما المخارج المرغوبة فهي تلك المنتجة من قبل ANN. وبالتالي، ستحاكي القواعد المُعادة من قبل GP الأداء الوظيفي لـــ ANN. يمكن أن يعتبر هذا النوع من التقنيات كتقنية تعليمية، التي تتعامل فيها ANN كصندوق أسود.

وميزة ذلك هي أنه ليس من الضروري معرفة أي شيء حول الأداء الوظيفي الداخلي لـــ ANN. مع ذلك، قد يكون مرغوباً ببعض المعرفة عن البنية الداخلية والأداء الداخلي لـــ ANN بهدف التخفيض بشكل كبير لمساحة البحث عن القواعد. تُعرف المنظومات من هذا النوع، التي يوجد من أجلها بعض المعلومات حول كيفية عملها، بالصناديق الرمادية. يمكن باستخدام GP ادخال معلومات حول ANN عبر تشكيلة خوارزمية GP من أجل المهمة المصممة لـــ ANN. على سبيل المثال، إذا كان معلوماً بأن ANN تنفذ مهام تصنيف، قد تكون أنواع القواعد المرغوب الحصول عليها محدودة بقيم منطقية متفاديةً القيم العشرية. وهذا يزيل عدداً كبيراً من التعابير الرياضية التي سينفذ بها البحث، أي أن المنظومة ستكون أكثر فعالية. إذا أستخدم مستوى معين من معرفة ANN في النظام، فيمكن اعتبار التقنية كتقنية انتقائية بدلاً من تعليمية.

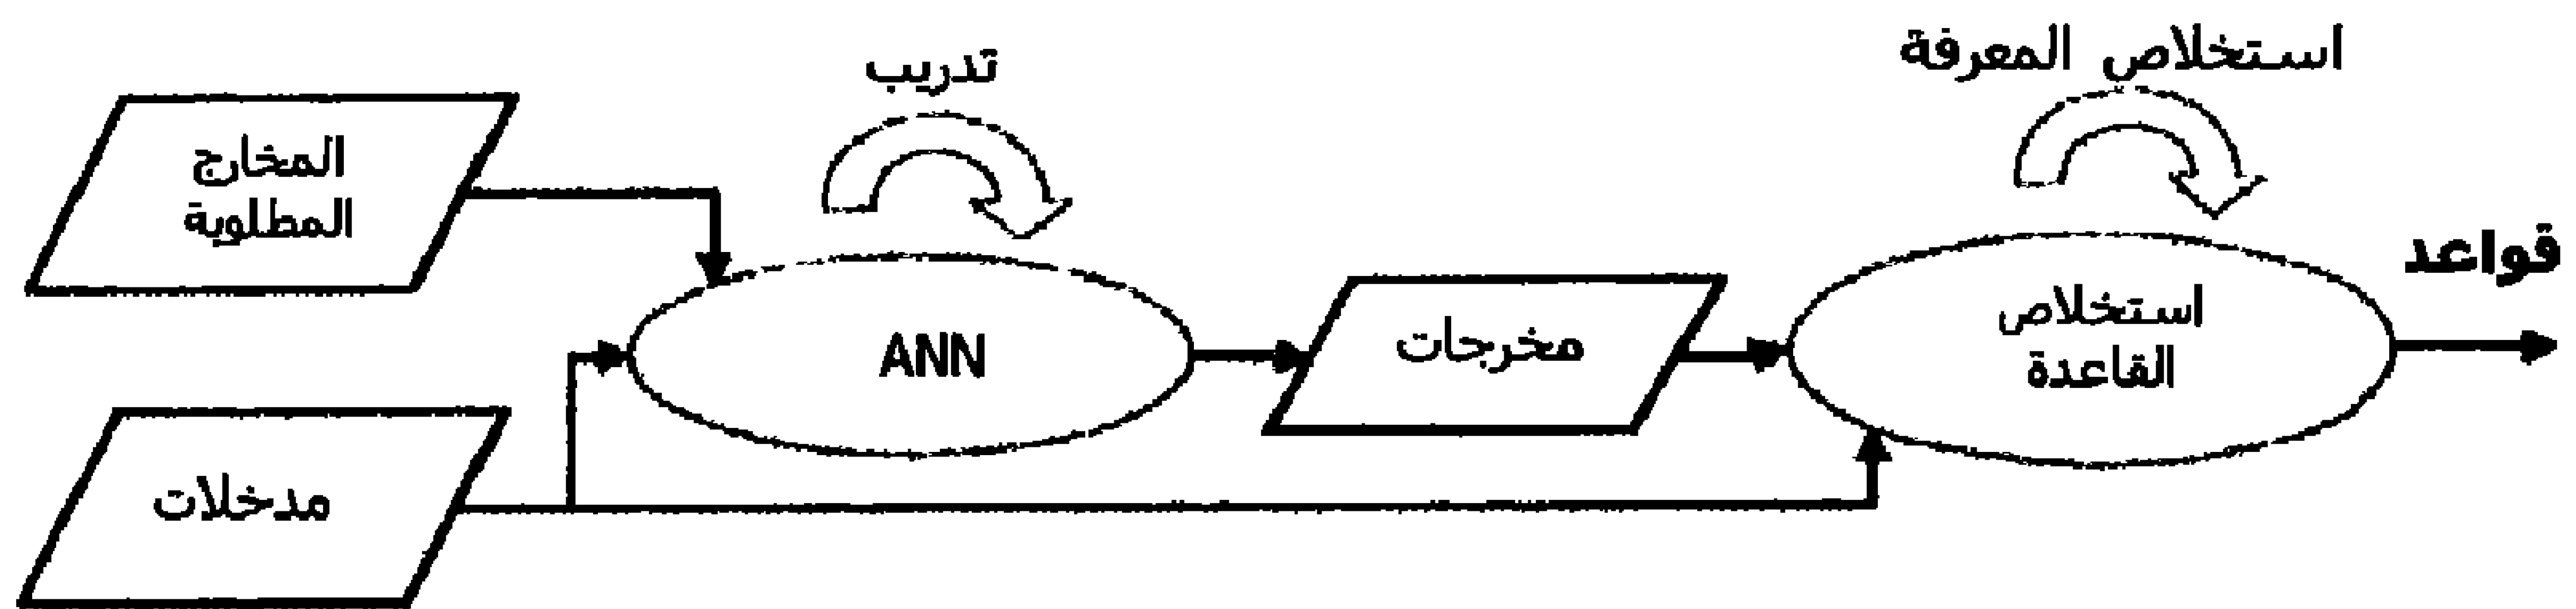
وصف النظام

تم اختيار المنهجية التعليمية من أجل الاستخدام، بغية الحصول على الاستقلالية الأعظمية للبنية الهندسية لـــ ANN وخوارزمية التعلم المستخدمة. بهذا الأسلوب، تُعتبر ANN كنظام قادر على تجريد الميزات للمسألة، التي تزود فيها المخرجات إلى أنماط الدخل المستخدمة. عند استخلاص

القواعد التي تشرح الأداء الوظيفي لـ ANN، سيكون الغرض اكتساب مبدأ عام لعملية التمييز وليس مساهمة السلاسل الفردية لكلٍ من عناصر الشبكة. وبالتالي - كما هو مذكور سابقاً - يمكن أن يُتعامل مع ANN، كأنها صندوق أسود أو تابع - وإن يكن عقدياً - يحول أنماط الدخل إلى أنماط خرج.

كما هو مذكور سابقاً - تتضمن العملية التي ستُنفذ اكتشاف قواعد ANN المعتمدة على أنماط دخل - خرج. تُطبق المدخلات على ANN، وباستخدام المخرجات الناتجة تُبنى أنماط "مجموعة تدريب مدخلات - مخرجات ANN". ستستخدم الخوارزمية الحثية GP هذه الأنماط بغية تحديد مقدار الضبط المنجز بالقواعد المكتسبة (ملاءمة) بالزوج "مخرجات (ANN) - مخرجات مكتسبة (قواعد)". (Rabuñal, 2004). حالما يتم تصميم وتدريب ANNs، قد تُستخدم نفس قيم التدريب والاختيار بغية توليد نمط بيانات ثاني، سوف يُستخدم للبحث عن القواعد التي اكتسبتها ANN خلال عملية التدريب. يظهر (الشكل 1) رسماً تخطيطياً لما يشبه العملية.

الشكل (1) *عملية استخلاص قواعد ANN*



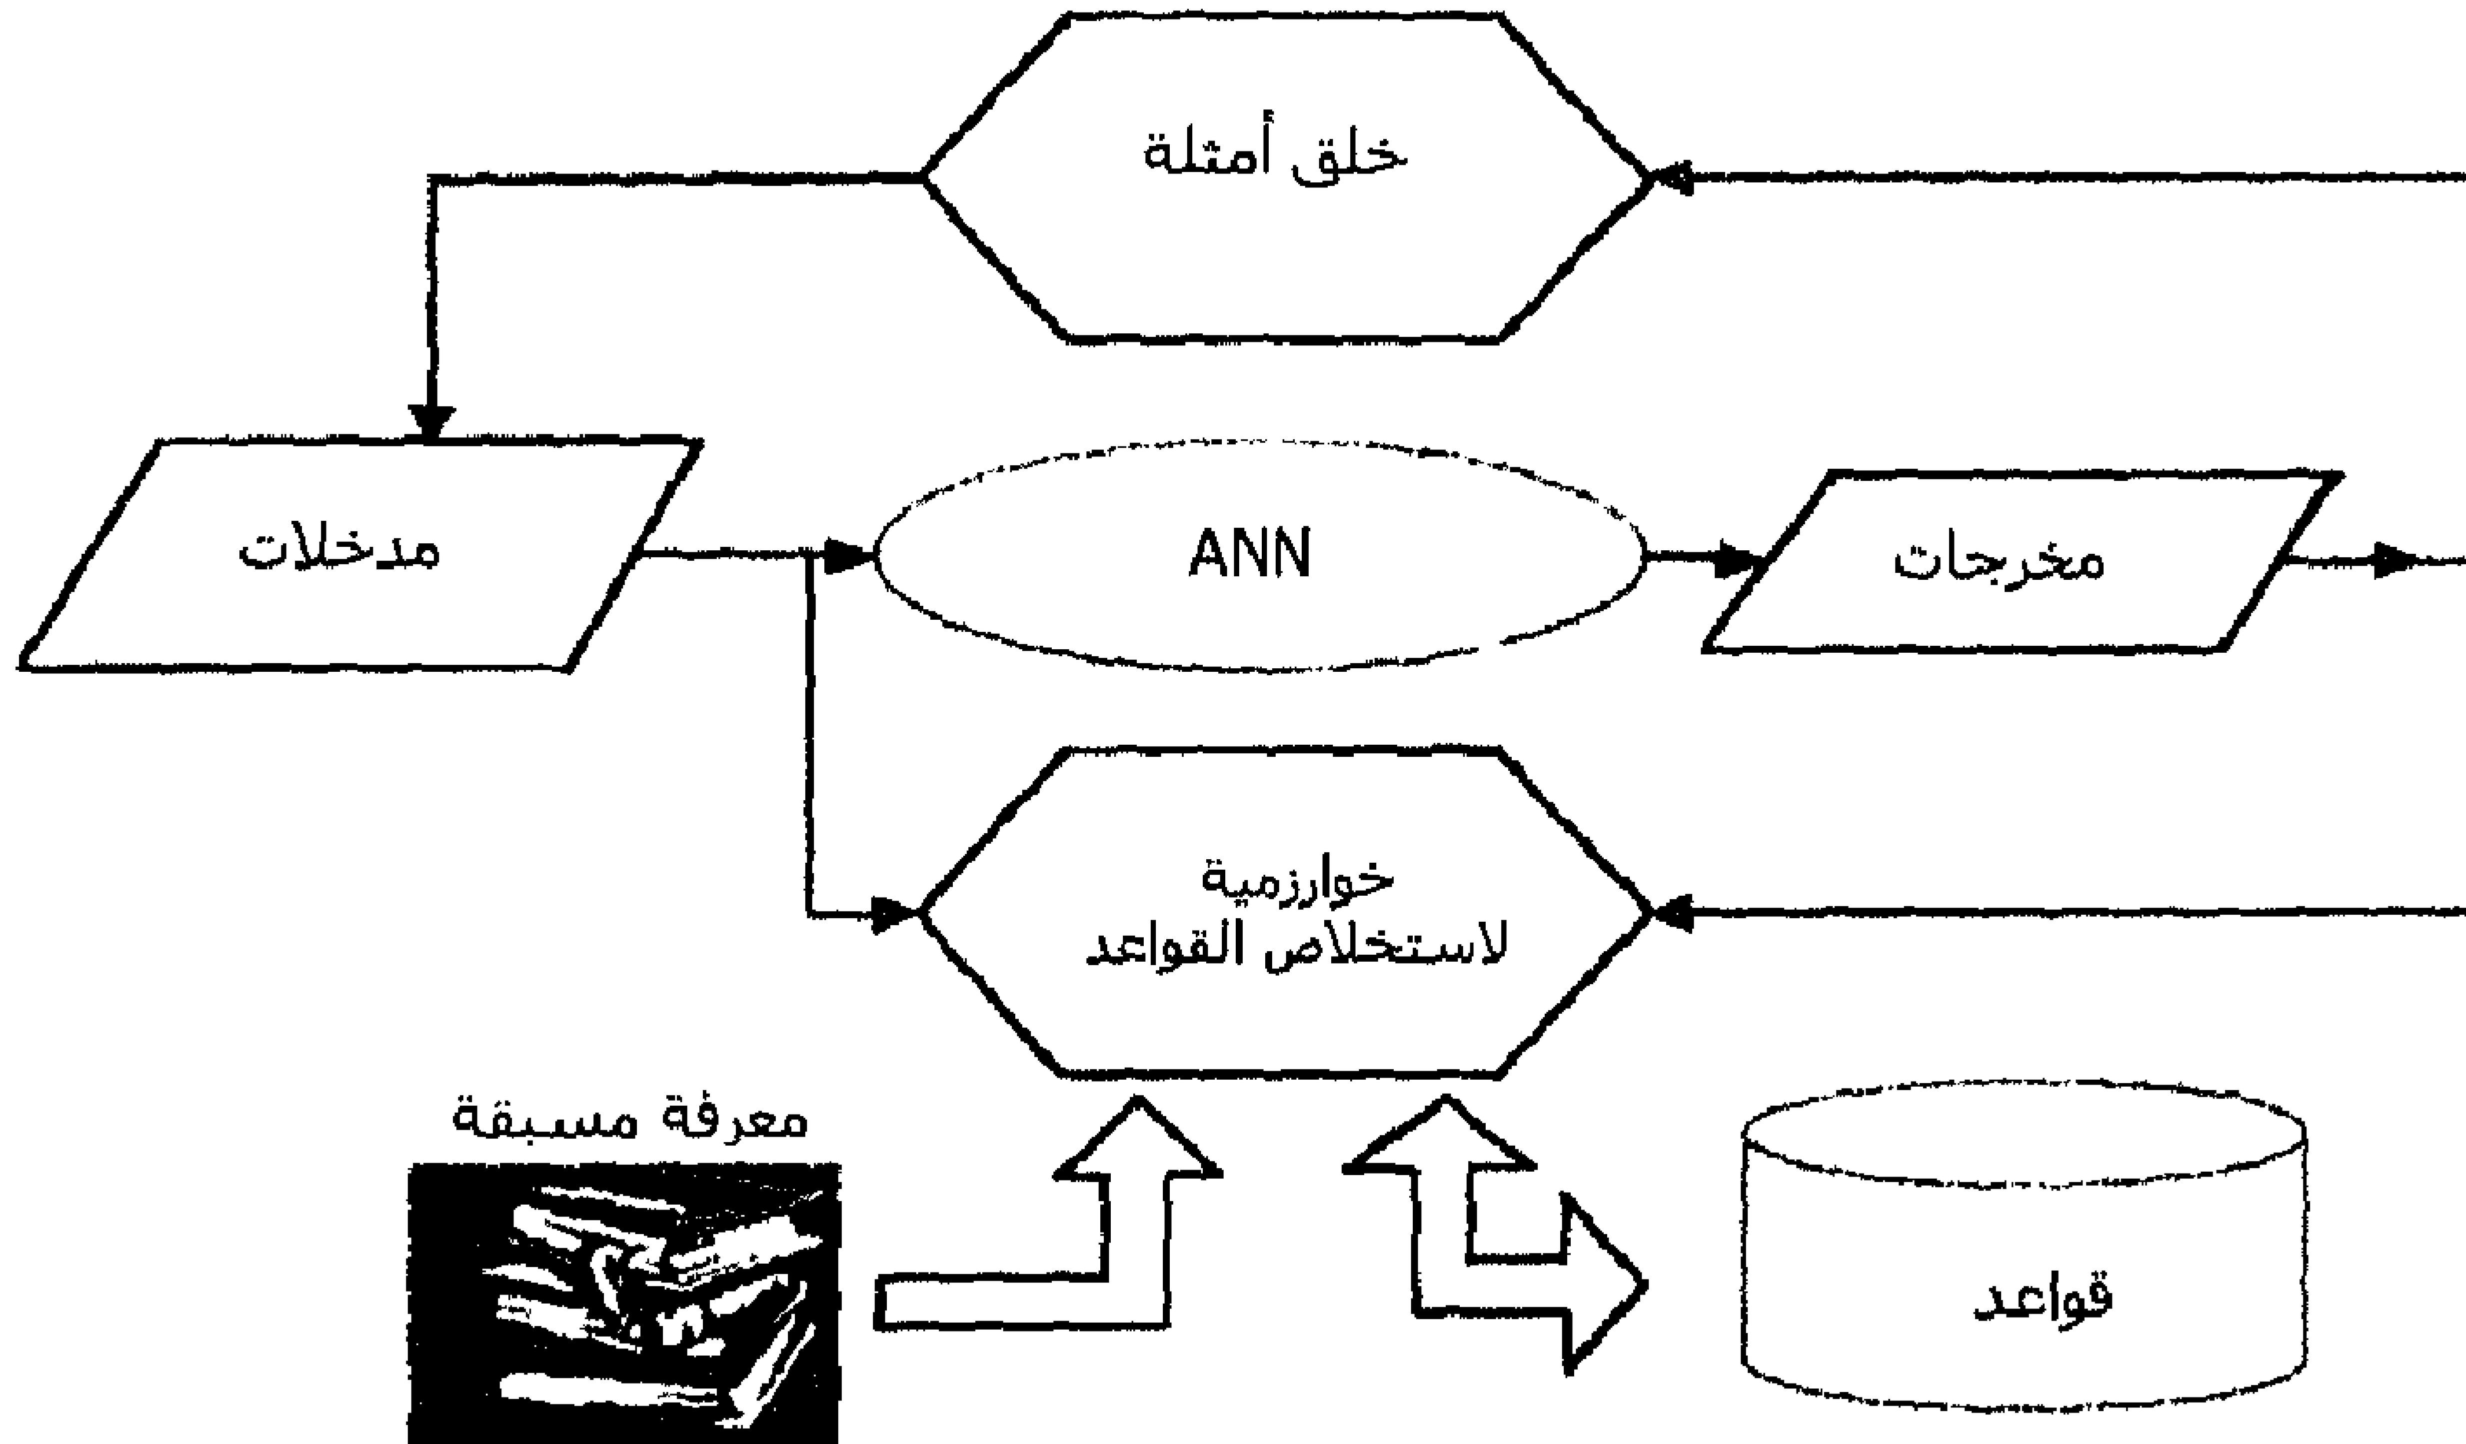
سوف تتضمن هذه المعرفة المسبقة المعلومات حول نوع البيانات المستخدمة من قبل ANN، أو نوع المسألة التي يُحاول حلها. على سبيل المثال، إذا كان معلوماً بأن ANN تعمل بشكل خاص على القيم المنطقية، فقد يكون ممكناً منع خوارزمية الاستخلاص من محاولة البحث عن القواعد التي تتضمن معاملات مستمرة أو متغيرات. بهذا الأسلوب، يكون من الممكن تخفيض مساحة البحث، التي على الخوارزمية استكشافها مع تحسين لاحق في الفعالية، اعتماداً على كمية المعرفة المُمتلكة حول الشبكة ونوع المسألة المُتعامل معها. يعرض (الشكل 2) مخطط عملية الاكتشاف اللاحقة لتطوير نظام اكتشاف القواعد.

اكتشاف قدرة التعميم

السمة الأخرى التي ستؤخذ بالحسبان عند تصميم آلية الاكتشاف، هي أن هذه الآلية قد تُوسّع بغية تحديد ميزة هامة مُقدمة من قبل ANNs، والتي أصبحت أحد الأسباب الرئيسية لنجاحها:

وهي قدرة التعميم. يكمن الغرض في استخلاص المعرفة التي تحصل عليها ANN من أنماط التدريب ومن حالات الاختبار غير المزودة خلال عملية التعلّم.

الشكل (2) *عملية استخلاص القواعد*



لهذا الغرض، علينا تصميم خوارزمية لخلق حالات اختبار جديدة، ستُطبق على ANN سامحةً لأدائها أن يُحلّل عند مواجهتها بمجالات جديدة، بالإضافة إلى اكتشاف حدودها الوظيفية. تكون هذه السمة ذات صلة خاصة عند تطبيق ANNs في بعض المجالات ذات الخطر الكبير من الناحية العملية كمراقبة منشآت الطاقة النووية، وتشخيص بعض الحالات الطبية، وقد استعملت بشكل واضح في المراجع والمنشورات العلمية حول ANNs، واكتشاف القواعد لحد الآن. الحالة المثالية التي ستكون قادرة على استخلاص المعرفة حول قدرة التعميم لـــ ANN، سوف تكون بتحليل النتائج المنتجة من قبل ANN، عندما تُقابل بكافة التوليفات الممكنة لقيم الدخل. على أية حال، يصبح ذلك غير قابلٍ للتطبيق عندما تزداد مساحة البحث.

بمعنى، أنه سيكون من الضروري التزويد بآلية تشكيل الاختيارات اعتماداً من أي من توليفات الدخل - الخرج (مجموعة الأمثلة) سوف تستخلص المعرفة. سيتضمن بديل واحد اختيار مجموعة جزئية من هذه التوليفات عشوائياً، وفي توزيع غير منتظم. وهذا يؤدي إلى الحصول على عدد قليل نسبياً من الأنماط، بمعنى أنه لا تتطلب عملية استخلاص القواعد قدرة حسابية هائلة. مع ذلك، فإن هناك عائق مضمونه، أنه لا يوجد ضمان بأن كل التوليفات قد أُختيرت، والذي يجعل من الممكن استخلاص كافة قدرات التعميم لـــ ANN.

بالنسبة لاكتشاف قدرة التعميم، تم تصميم خوارزمية معروفة بـ "خوارزمية خلق الأنماط الجديدة". قد تُخلّق حالات اختبار جديدة باستخدام هذه الخوارزمية جاعلةً من الممكن اكتشاف قواعد وتعابير تلك الأجزاء من الأداء الوظيفي الداخلي لـ ANN، التي لم تستكشف من قبل أنماط التعلّم. لسنا متأكدين من أن سلوك ANN يطابق سلوك الواقع الخارجي، ولكننا فقط نتمنى ذلك. الغرض الوحيد من استخدام حالات الاختبار الجديدة هو تقليد نموذج ANN بشكل أفضل. وهو لا يمكن أن يكون ممتداً بالضرورة إلى النقطة التي ستقلد مجموعة القواعد بشكل أفضل للمسألة المأخوذة بالاعتبار. لهذه الغاية، نبدأ بأنماط التعلّم بتطبيق خوارزمية اكتشاف القواعد عليها التي استخدمت مسبقاً عبر GP، يعتمد الحل المستخدم على المسلمة التي تقول: "بأن كافة ANNs تحصل على القدرة للتعميم من المعرفة الضمنية لملفات التدريب". وهذا يعني أنه يتوجب على خوارزمية خلق الأمثلة استعمال هذه الملفات. إضافة إلى ذلك، فهي ستكون مزودة بمجموعة جديدة من توليفات الدخل المختارة عشوائياً والمعتمدة على المدخلات من الملفات السابقة.

بتحديد وجود مثل هذه المجموعة من المدخلات الجديدة، يجب أن يعين حجمها. فإذا كانت صغيرة، فإن تأثيرها سيكون بالكاد ملحوظاً في النتيجة النهائية. وعلى النقيض من ذلك، فإن كانت كبيرة جداً فستجعل الحلول تمتد نحو المعلومات المزودة من قبل هذه المدخلات الجديدة مُقللةً مساهمة أنماط التدريب الأصلية. حالما يتم الحصول على ضبط جديد، تُطبق خوارزمية خلق الأنماط الجديدة، وذلك بتوليد سلسلة من أنماط دخل جديدة تُطبق على ANN للحصول على النواتج ذات الصلة. تُضاف هذه الأنماط الجديدة "مدخلات جديدة - مخرجات ANN" إلى أنماط التدريب مجدداً عملية اكتشاف القواعد. يجب ذكر بأنه بغية الاستمرار بعملية الاكتشاف، فإن الخطوة الأولى هي إعادة تخمين كل سلسلة فردية في المجتمع بغية حساب ضبطها الجديد. وعندما يحدث ذلك، يمكن لعملية الاكتشاف أن تستمر.

بينما تتقدم عملية استخلاص القواعد، يكون من الممكن إزالة الأمثلة بحيث تكون القواعد المكتسبة حتى الآن قد اُكتسبت من مجموعة المدخلات الجديدة. عندما توجد حالة اختبار جديدة، يتطابق فيها خرج ANN مع ذلك المُنتج من قبل التوليفة الأفضل للقواعد المكتسبة، عندئذ تُزال حالة الاختبار تلك، لأنه تم اعتبار بأن القواعد المحصول عليها قد اكتسبت المعرفة الممثلة بحالة الاختبار تلك. كما أنه من الممكن إضافة أمثلة جديدة في الوقت نفسه مايجعل من الممكن استكشاف مناطق جديدة من فضاء البحث. ستبقى الأمثلة المزودة من قبل ملفات التدريب ثابتة طوال العملية، بمعنى أنها ستقدم دائماً إلى خوارزمية استخلاص القواعد.

بالتالي، تُنفذ العملية بأسلوب تكراري: يُقلّد (يُنفذ) عدداً من التوليدات أو المحاكاة لخوارزمية اكتشاف القواعد، وبمجرد الانتهاء من ذلك، تّولد حالات جديدة، ثم تُزال تلك الحالات التي تتطابق نتائجها مع نتائج ANN. حالما تُزال كافة حالات الاختبار ذات الصلة، تُخلّق حالات جديدة بغية ملء الفجوات المهجورة من قبل تلك الحالات التي حُذفت. تقارن كل حالة جديدة بأخرى موجودة بغية تحديد فيما إذا كانت موجودة في حالات الاختبار. في هذه الحالة، تُزال وتُخلّق حالة أخرى جديدة بنفس الأسلوب. ومن ثم تبدأ العملية من جديد بتشغيل خوارزمية الاكتشاف N توليد، ومرة أخرى تكرار الإزالة وخلّق حالات جديدة. ستكتمل هذه العملية، عندما يقرر المستخدم بأن القواعد التي تم الحصول عليها هي المطلوبة.

البارامترات المستخدمة من قبل "خوارزمية خلق أنماط جديدة" موصوفة بالتفصيل في Rabuñal (2004) مع وصف أفضل صياغة وأكثر منهجية للخوارزمية.

بغية توليد أنماط دخل جديدة من تلك الموجودة سابقاً، يمكن تطبيق عدد من البدائل المختلفة: خلق كافة القيم الجديدة عشوائياً، أو البدء ببعض الأنماط الأصلية وتعديلها في طريقة ما بغية توليد دخول جديد. باستخدام الطريقة الأولى، يكون من الممكن توليد أنماط متفاوتة كثيراً عن بعضها، ولا تنسجم مع مناطق البحث التي تعمل بها ANN، الأمر الذي قد يقلل من صلاحية القواعد المكتسبة، مع ذلك قد يكون من المشوق فحص كيفية استجابة ANN في الحالات الشديدة. في حالة البديل الثاني، يُختار واحد من أنماط التدريب عشوائياً، وبتعديل قيمته بعض الشيء ويتم بناء حالة مثال جديدة. بهذا الأسلوب، تولد المدخلات التي لا تكون بعيدة جداً في خصائص البحث عن حالات التدريب. وبالتالي، سيكون الهدف في إنتاج سلاسل دخل جديدة التي منها تُولّد كافة سلاسل الخرج الممكنة، والتي تكون من أجلها قد دُرِّبت الشبكة. على الرغم من أن خوارزمية توليد الأمثلة مستقلة كلياً عن البنية الهندسية لـــ ANN، فإن واقع العمل مع شبكة أمامية الانتشار أو تكرارية يعني بأن الخوارزمية مختلفة تماماً.

عند العمل مع شبكات تكرارية لن يكون كافياً مقارنة الخرج المقدم من قبل RANN مع المقدم من قبل القواعد من أجل نمط دخل لتحديد ما إذا اكتسبت القواعد المعرفة الصحيحة أم لا. وهذا ناجم عن حقيقة أن الأداء الوظيفي لـــ RANN لا يعتمد على أنماط دخل السلاسل الفردية، وإنما بدلاً من ذلك يعتمد على سلاسل المدخلات. هذا يعني، أنه يمكن القول فقط بأن سلوك RANN يُكتسب عندما تقدم القواعد نفس النواتج مثل RANN نفسها من أجل كافة القيم لسلسلة المدخلات.

يستخدم الحل المُتخذ في الحالة الخاصة لـــ RANN ملفات التدريب كقاعدة أولية، بغية توليد سلسلة بداية جديدة، تُطبق كدخل إلى ANN، سوف تنتج التوليفات دخل – خرج اللاحقة.

على سبيل المثال، إذا استخدمت RANN من أجل تنبؤ سلاسل زمنية قصيرة الأمد، فإنها ستعمل كنظام تغذية عكسية: تُعطى القيمة في اللحظة t، وتتوقع الشبكة القيمة في لحظة t + 1، ثم تزود هذه القيمة في اللحظة t + 1 كدخل لتوقع القيمة في اللحظة t + 2 وهكذا...

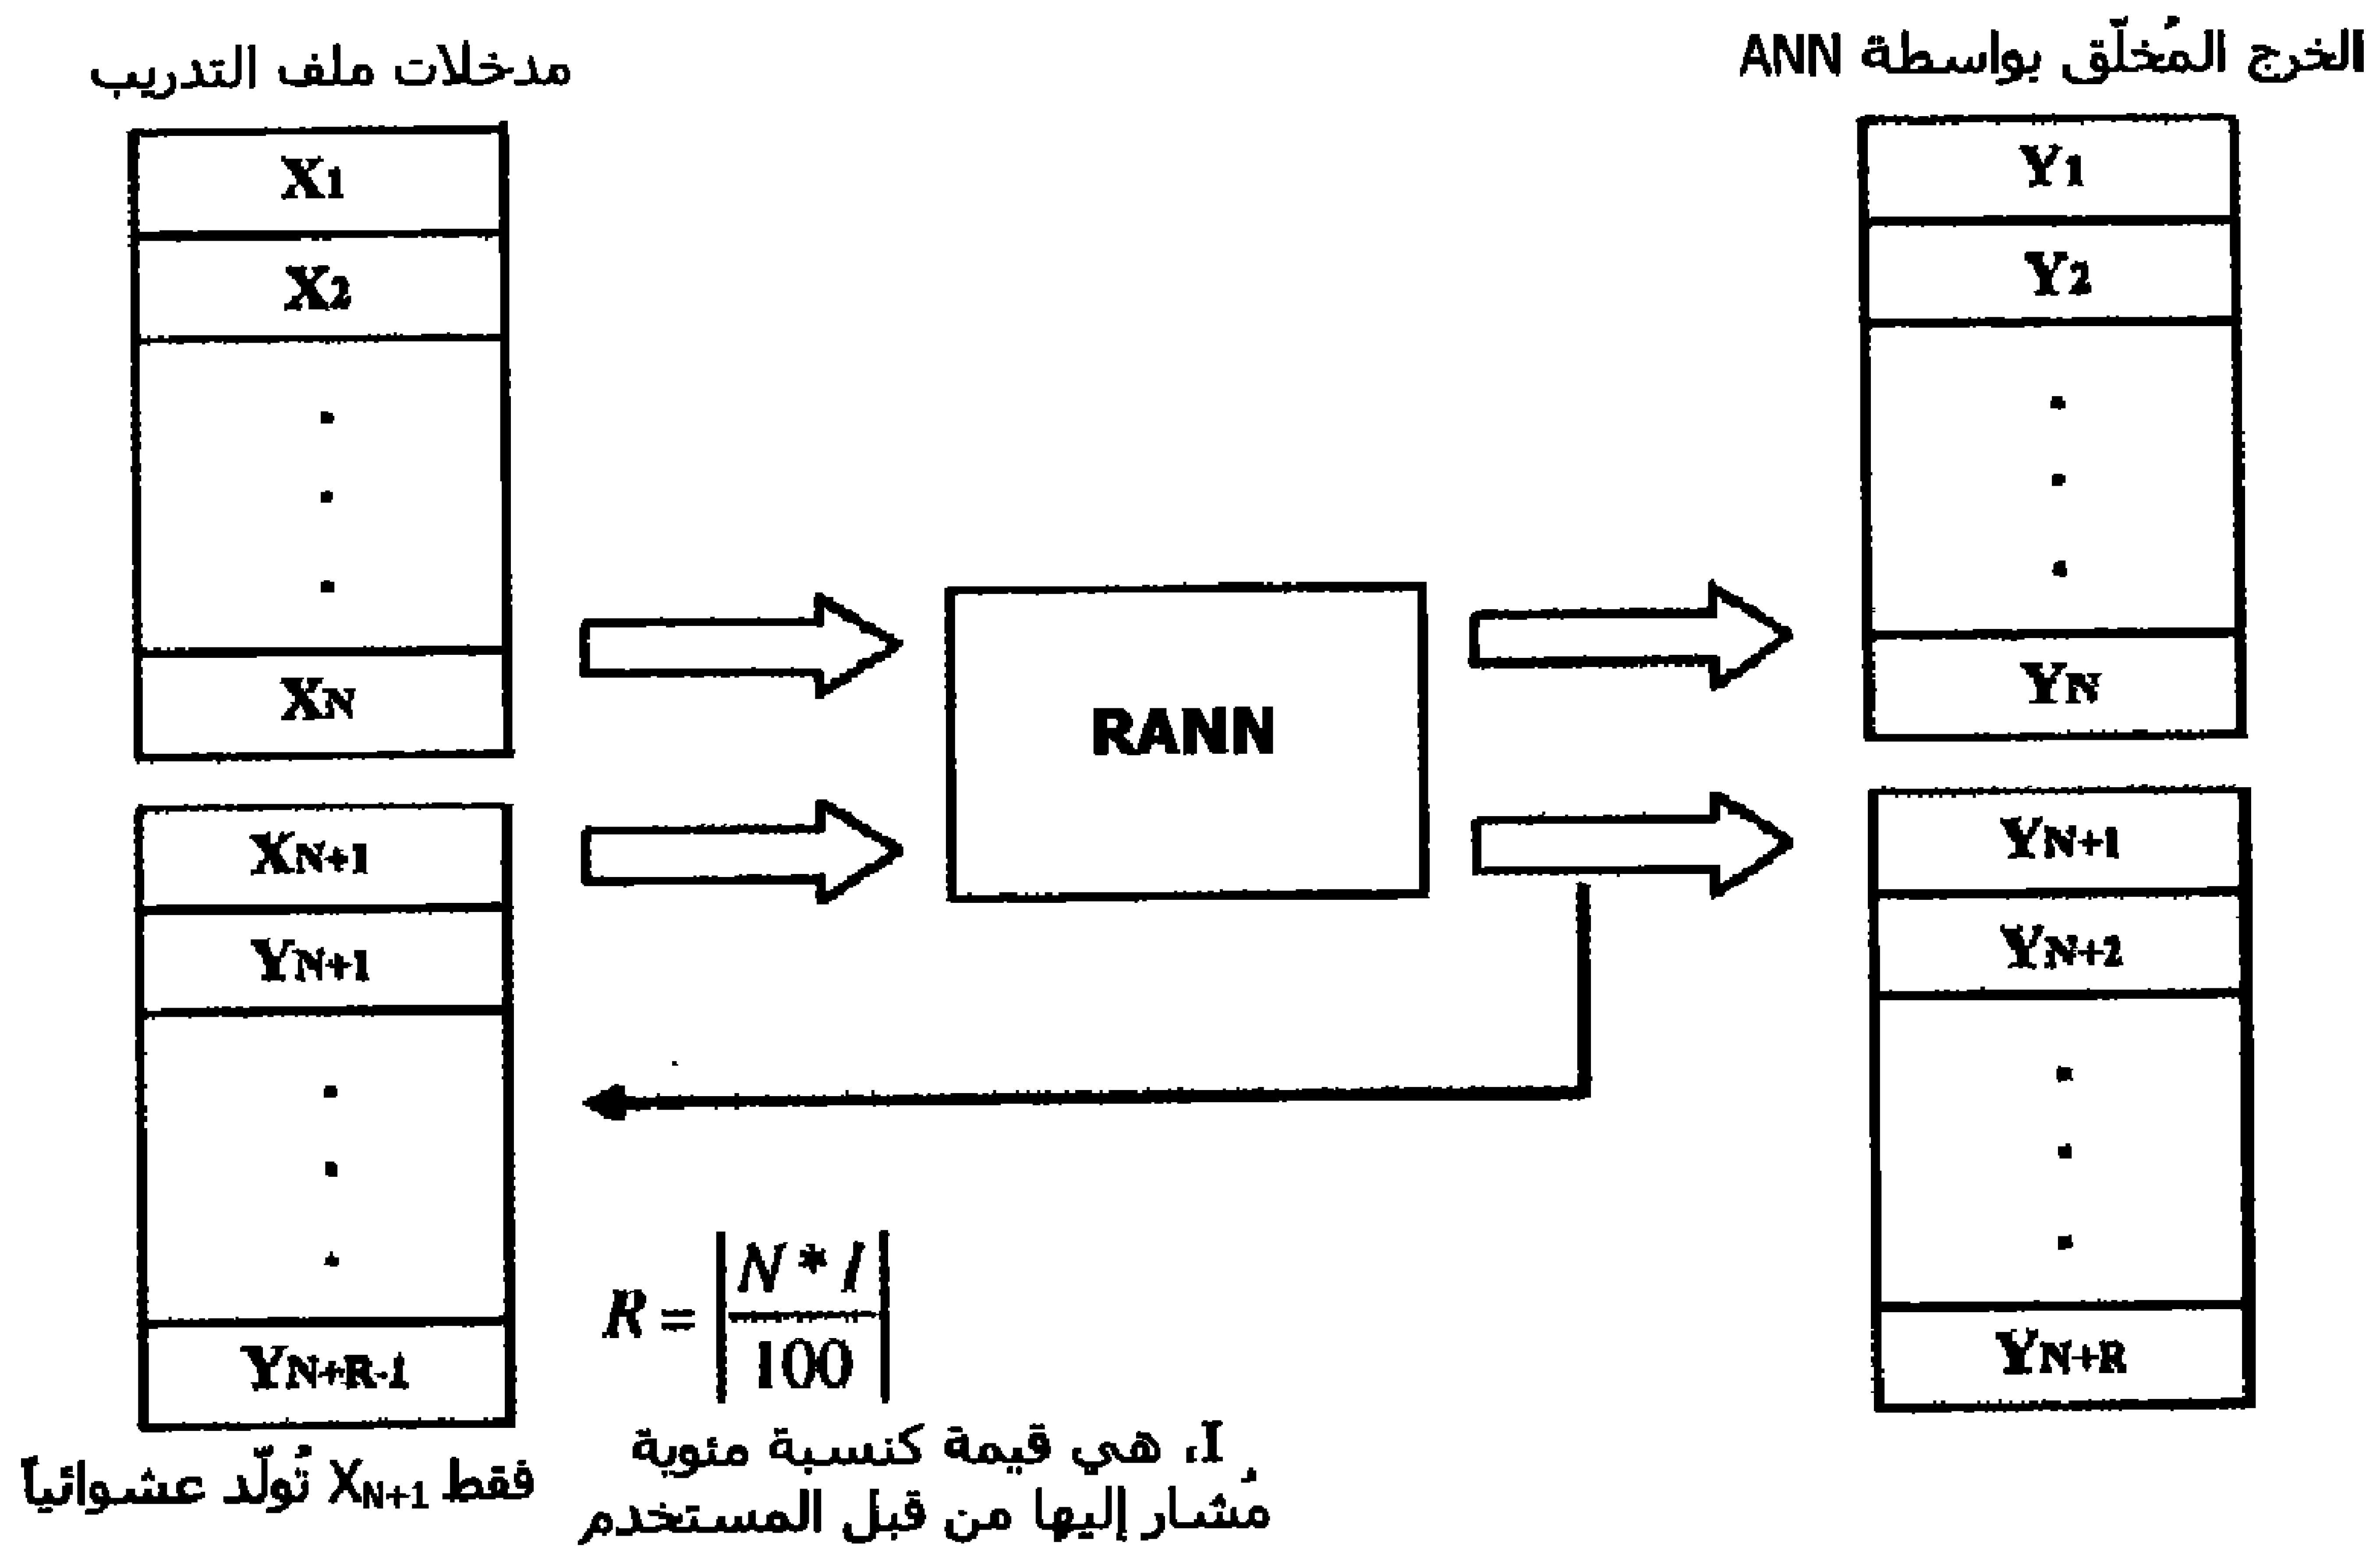
سوف تُزال سلسلة المدخلات عندما تحاكي القواعد سلوك كافة قيم السلسلة بخطأ أقل من عتبة معينة مسبقاً، وذلك عندما تتطابق سلسلة قيم الخرج ANN المكتسبة من القيمة الجديدة المُخلقّة مع السلسلة المكتسبة بتطبيق القواعد المستخلصة حول هذه القيمة. عندما يحدث ذلك، يجب تخليق قيمة دخل جديدة، ستولد منها سلسلة جديدة من المدخلات، بحيث يمكن أن تبدأ عملية استخلاص القواعد من جديد.

في حالة العمل مع RAN، يكون لدى النظام سلسلة من البارامترات الإضافية. وهي ستملك بالإجمال البارامترات التالية:

- **النسبة المئوية للأنماط الجديدة**: كم هو عدد الأنماط الجديدة التي ستستخدم عدا أنماط التدريب. في حالة عدم العمل مع السلاسل الزمنية، تُفحص هذه الأنماط الجديدة بحيث تكون مختلفة عند أنماط التدريب. بينما في حالة العمل مع السلاسل الزمنية تُضاف هذه الأنماط العشوائية الجديدة إلى نهاية السلسلة المستخدمة للتدريب.
- **احتمال التغيير**: تركز عملية خلق حالات اختبار جديدة على توليد سلاسل جديدة من بيانات التدريب. تُختار سلسلة المدخلات عشوائياً من ملف التدريب. يتم من أجل كل دخل المحافظة على نفس القيمة أو تُولّد قيمة جديدة عشوائياً تبعاً لاحتمال معين. هذه التقنية مشابهة لعملية الطفرة لـــ EC.
- **الخطأ الأدنى للبقاء**: حالما تُبدأ العملية لاستخلاص القواعد، وعندما تُولّد هذه القواعد فهي تعكس الأنماط التي تم التدريب معها. وعندما تعكس القواعد المستخلصة بشكل كاف سلوك ANN بنمط مُعطى، لا يعود لهذا النمط أية ضرورة، لذا يُنبذ ويخلق نمط جديدٌ. يدل هذا البارامتر إلى اللحظة التي يجب أن يُنبذ فيها نمط ما، وذلك عندما تكون قيمة الخطأ المكتسبة للقواعد في هذا النمط المحدد أقل من عتبة معينة.
- **عدد نواتج التغذية العكسية**: عند العمل مع شبكات تكرارية يكون الهدف أيضاً دراسة سلوك الشبكة بأخذ النواتج التي تعيدها وتستخدمها كمدخلات. يشير هذا البارامتر إلى عدد الأنماط (بمجموعة الأنماط التي تدل على حجمها بواسطة البارامتر "النسبة المئوية للأنماط الجديدة") التي لن تُولّد عشوائياً، ولكن بدلاً من ذلك، ستكون نتيجة محاكاة الشبكة بأخذ كل دخل كخرج في اللحظة السابقة.

(الشكل 3) هو تمثيل بياني للفكرة. سيتنوع أيضاً أسلوب إزالة سلسلة الأمثلة. تُخلق في هذه الحالة فقط قيمة عشوائية. سيكون معيار الإزالة هو عندما تمتلك سلسلة جديدة مُخلّقة R خطأ صغوي مقارنة مع تلك المنتجة من قبل RANN، أو عندما تستوعب القواعد المعرفة الموجودة في كافة السلاسل الجزيئية للحالات الجديدة. وكنتيجة، سوف تُزال جميعها. أما الخطوة التالية، فستكون خلق قيمة عشوائية جديدة واستخدامها لبناء سلسلة جديدة والبدء بعملية الاستخلاص من جديد حتى تحقيق الضبط... وهكذا.

الشكل (3) *العملية الابتدائية لخلق أمثلة في حالات RANN وANN مؤقتة*



كما يلاحظ في (الشكل 3)، يحدث تداخل في سلسلة المدخلات المُخلّقة بين المدخلات (X) والمخرجات كنتيجة للقيمة الأولى المولدة عشوائياً. بهذا الأسلوب، يكون من الممكن تحليل أسلوب RANN المُقابلة بتعداد السلاسل المستقبلية الممكنة، وتلخيص كامل معرفة التعميم في اتصالاتها التكرارية.

من الهام هنا ملاحظة أنه بغية الحصول على خرج، لا تأخذ RANN بالحسبان قيمة الدخل في اللحظة التالية وحسب، بل والمخارج من لحظات سابقة لها تأثير أيضاً. أي أنها تمثل استخدام قدرة الذاكرة الداخلية المزودة بالتغذية العكسية. وبالتالي، يجب أن يُشكل كل جهد لضمان بأن هذه المعلومات المخزنة في ANN لاتؤثر في المخارج المرافقة مع الانماط الجديدة المُخلّقة بالتغذية

العكسية. وللقيام بذلك، يتم قبل توليد سلسلة الأمثلة الجديدة إدخال سلسلة قيم مُولّدة عشوائياً إلى ANN، بحيث لا تُحدَّد الذاكرة الداخلية بالأمثلة السابقة.

استخلاص القواعد بـ RANN للتنبؤ بالسلاسل الزمنية

عند العمل بـــ RANN المؤقتة لتوقع السلاسل، فإن البيانات المستخدمة خلال عملية التدريب هي عادةً قيم أو قياسات مأخوذة من عملية حقيقية. على سبيل المثال، في توقع البقع الشمسية تُمثل كمية البقع الشمسية المنتجة سنوياً، ولا يمكن أنه تغيّر هذه القيم. في هذه الحالة، تكون المجاهيل هي القيم المستقبلية وسلوك ANN لتوقع هذه القيم.

في حالة التنبؤ قصير الأمد يكون الهدف من أجل ANN، أو في حالات أخرى من أجل القواعد المستخلصة من أدائها، هو تنبؤ قيمة الخرج في اللحظة t [Y(t)] باستخدام قيم الدخل X(t) ومخارج اللحظات السابقة Y(t - 1), ..., Y(t - n).

وتكون العملية مختلفة قليلاً من أجل التنبؤ طويل الأمد. وفي هذه الحالة، تكون قيم الدخل معلومة حتى اللحظة t - X(1), ..., X(t) - ويكمن الهدف في تنبؤ قيم الخرج في لحظة ما مستقبلية. في اللحظة t = N مثلاً. في هذه الحالة، يعاد إدخال المخارج المزودة من قبل ANN في لحظة ما مُعطاة كمدخلات للدورة التالية. وهذا يعني، بأنه يمكن الحصول على قيم Y(N) من القيم X(1), ..., X(t), Y(t), Y(t + 1), ..., Y(N - 1).

إن استخلاص القواعد هو نفسه في كلا الحالتين، والذي يختلف هو تكييف هذه القواعد اعتماداً على ما إذا ستُعطى الأهمية الكبرى للتنبؤ قصير الأمد أم طويل الأمد. ويحدد هذا التكييف بمقارنة قيم الخرج المزودة من قبل ANN والقواعد نفسها. يكمن الاختلاف في كيفية الحصول على المخرجات للقواعد في حالة الأمثلة المُخلّقة بالتغذية العكسية (أنماط X(i + 1), ..., X(i + n) في الشكل 3).

هذا يعني، بأنه بغية اختبار كيفية ضبط القواعد لسلوك ANN، يكون من الضروري مقارنة – اعتباراً من لحظة ما مُعطاة t = i – الخرج المزود من قبل ANN ($Y - ANN_{t = i}$) مع الخرج المكتسب باستخدام القاعدة ($Y - Rule_{= i}$). في حالة التنبؤ قصير الأمد، تستخدم القاعدة في الحلقات اللاحقة المخرجات المعطية من قبل ANN في اللحظة السابقة كمدخل:

$$X - Rule_{t = i + 1} = Y - ANN_{t = i}$$

يكمن الغرض هنا في أنه تُفضل القواعد التي تضبط أفضل سلوك ANN في لحظة ما مُعطاة باستخدام معلومات من المخرجات السابقة فقط لـــ ANN.

على نقيض من ذلك، في حالة التنبؤ طويل الأمد، تستخدم القاعدة خرج التغذية العكسية من القاعدة في اللحظة السابقة تماماً كقيمة دخل في اللحظة i + 1. بهذا الأسلوب، يكون الخرج في اللحظة t + n (تنبؤ طويل الأمد) سلسلة موجهة من المخرجات المزودة من قبل القواعد وليس من قبل ANN من اللحظة i:

$X - Rule_{t=i+1} = Y - Rule_{t=i}$

أمثلة القواعد المكتسبة

أيّاً كانت المنهجية المختارة لاستخلاص القواعد، فإن إحدى الخطوات الأكثر أهمية تتضمن الأَمْثَلة أو المعالجة العليا للقواعد المكتسبة. وهذه الأمْثلة ضرورية للأسباب التالية.

- يمكن أن تُلخص عدة قواعد عينة في قاعدة واحدة أكثر عموميةً.
- قد تظهر إسهابات (زيادة عن الحاجة) بين القواعد المكتسبة.
- قد تُبسط العديد من القواعد فقط بإعادة كتابتها بطريقة مختلفة.

إضافة لذلك، تتضمن عملية الأمْثلة التبسيط و/أو خلق عمليات رمزية بين القواعد.

قد تُطبق تقنيات أَمْثَلة متنوعة اعتماداً على طريقة الاستخلاص المستخدمة وعلى نوع القواعد المكتسبة. ويمكن أن تُقسم هذه التقنيات إلى مجموعتين: طرق استدلالية، وطرق أَمْثَلة ضمنية. تُشكّل المجموعة الأولى بشكل عام بخوارزميات التحليل التركيبي، وأحد الأمثلة هو استخدام لغة Prolog لتنفيذ التبسيط والصلاحية للقواعد الجديدة المكتسبة. وللقيام بذلك، تُولد سلسلة من المتغيرات اللغوية، التي تُستخدم فيما بعد لإيجاد القواعد المُبسطة التي تستخدم هذه المتغيرات.

تُشكل طرق الأَمْثَلة الضمنية بمجموعة من التقنيات المستخدمة في خوارزميات اكتشاف القواعد، التي تؤدي جوهرياً إلى خوارزمية اكتشاف قواعد مُحسنة. كما ذكرنا، اُختيرت GP كخوارزمية استخلاص القواعد. قد تُستخدم أحدى بارمترات التشكيل الكلاسيكي لـــ GP – الاقتصاد أو الجزء المعمَّق – في عملية أَمْثَلة القواعد المكتسبة.

في المصطلحات المعتمدة، عندما يُقيّم مستوى التكّيف لسلسلة فردية وراثية – في هذه الحالة تكون كل سلسلة فردية أو شجرة هي التمثيل لقاعدة ما – تُخفض قيمة جودته بمقدار قليل اعتماداً على عدد العقد الطرفية وغير الطرفية التي يقدمها. وكلما كان عدد العقد أكبر، ازداد مقدار تُخفيض قيمة جودته. تُستخدم هذه الطريقة للإعانة في خلق قواعد أبسط تكون بالتالي أسهل للتفسير.

تشكيل بارامتر GP

الخطوة التالية في اكتشاف القواعد هي الحساب العددي للبارامترات المتضمنة في الخوارزمية. تُستخدم التجريب لضبط البارامترات المتعلقة بـــ GP. والبارامترات المُطبقة هي التالية:

الجدول (1) بارامترات GP الممكنة وقيمها

البارامتر	الخيارات
خوارزمية خلق المجتمع	كاملة جزئية نصف على نصف
خوارزمية الاختيار	بطولة (سلسلة مباريات) روليت باقي عشوائي عام عشوائي عينة حتمية
خوارزمية الطفرة	شجرة جزئية نقطية
إستراتيجية انتخابية	نعم ـ لا
معدل التصالب	0 - 100%
معدل الطفرة	0 - 100%
احتمالية اختيار غير منهجية	0 - 100%
حجم المجتمع	عدد السلاسل الفردية
مستوى الاقتصاد	القيمة الجزائية

عند تعيين معاملات طرفية وغير طرفية يجب تحديد النوع: يكون لكل عقدة نوع، وتطلب العقدة غير الطرفية نوعاً معيناً من نسلها (Montana, 1995). وهذا يضمن، بأن الأشجار المولدة بهذا الأسلوب تُحقق القواعد اللغوية المعينة من قبل المستخدم، إضافة إلى ذلك، يجب على كلا مجموعتي المعاملات المعينة تحقيق متطلبين: الإغلاق والكفاية. ويجب أن يكون من الممكن بناء أشجار صحيحة بالمعاملات المعينة والتعبير عن حل المسألة (التعبير الذي نبحث عنه) باستخدام هذه المعاملات. يجب أن ينفذ تحليل تجريبي بغية ربط البارامترات المثالية، وتجريب توليفات مختلفة بغية ضبط القيم المتنوعة تدريجياً حتى إنجاز أفضل النتائج.

يتعلق الضبط البارامتري التالي بالعقد الطرفية وغير الطرفية، الذي سيأخذ حيزاً في تنفيذ الخوارزمية. إن المعرفة التي نملكها حول ANN سويةً مع أنواع المسائل التي من أجلها صُممت هذه الـــ ANN، ستكون كنتيجة في هذه الحالة. والبارامترات التي ستُختار هي التالية:

الجدول (2) العناصر الممكنة لمجموعات الطرفيات والتوابع

البارامتر	**الخيارات**
معاملات منطقية	AND, OR, NOT
معاملات رابطية	<، >، =، < >، = <، = >
توابع حسابية	+، -، *، % (التقسيم المحمي)
توابع القرار	IF - Then - ELSE على قيم حقيقية IF - THEN - ELSE على قيم منطقية
ثوابت	اختيار صف عشوائي أو مُعيّن يدوياً (مشيراً للصف أو واحد بعد الآخر)
متغيرات الدخل	بتحديد واحد بعد الآخر فيما إذ كان حقيقياً أو منطقياً.
نوع المخرجات	حقيقي منطقي تحويل الحقيقي إلى منطقي (بتعيين العتبة)

كما هو ملاحظ، توجد إمكانية لمجال واسع من التشكيلات. وكلما كان لدينا معلومات أكثر حول ANN، ازدادت سهولة تعيين قيم البارامترات المُفضلة في الأعلى. عدا ذلك، فإن التجريب مطلوب بغية تحديد ما هو الأفضل من أجل كل ANN.

النتائج

ينصح بالانتشار الأمامي للتصنيف

يعطي العالم (2004) Rabuñal وصفاً شاملاً لكيفية تطبيق ANNs في أنواع مختلفة من المسائل، بالإضافة إلى الاستخلاص اللاحق للقواعد من الشبكات المكتسبة باستخدام التقنية الموصوفة في هذه المقالة. المسائل المُعاد حلها في هذه الحالة هي تصنيف أزهار السوسن (Fisher, 1936)، والفطور السامة (Blake, 1998)، وتشخيص سرطان الثدي، والتهاب الكبد والتهاب الزائدة الدودية (Blake, 1998). يمكن إيجاد النتائج المكتسبة في حل هذه المسائل باستخدام البرمجة الوراثية وANN، بالإضافة إلى مقارنتها بالتقنيات الأخرى في المرجع (2004) Rabuñal.

بعد أن تكون الشبكة قد دُرّبت من أجل كل مسألة، تُطبق خوارزمية استخلاص القواعد باستخدام أنماط التدريب فقط كمدخلات وباستخدام خوارزمية خلق أنماط جديدة. يظهر (الجدول 3) مقارنة التسويات المكتسبة باستخدام أنماط التعلّم فقط مع تلك المنجزة باستخدام خوارزمية خلق أنماط جديدة. بغية إنشاء هذا الجدول، تم إنشاء ملف تحليلي بكافة القيم الممكنة لمتغيرات الدخل بأخذ مجالات منتظمة (مدخلات مُسواة).

باستخدام هذه المجالات، تحليل المجال الكامل المحتمل للتصنيفات التي تنفذها القواعد. يظهر (الجدول 3) قيم الضبط (التسوية) المُنتجة من قبل القواعد المكتسبة بكلا الطريقتين، عندما تُقيّم أنماط الملف التحليلي.

الجدول (3) قيم الضبط المكتسبة في عملية استخلاص القواعد باستخدام فقط أنماط التدريب وخوارزمية خلق أمثلة جديدة.

الطريقة	المسألة						
	زهرة السوسن						
	مشوهة	متعددة اللون	بكرية	سرطان الثدي	التهاب الكبد	الفطور السامة	التهاب الزائدة الدودية
بدون تخليق ديناميكي	% 63.34	% 56.97	% 57.23	% 64.56	% 59.95	% 77.44	% 78.93
مع تخليق ديناميكي	% 95.45	% 88.81	% 77.88	% 71.91	% 73.34	% 82.51	% 85.97

تنبؤ السلاسل الزمنية

يجب أن تُستخدم البنى الهندسية لـــ RANN من أجل تنبؤ السلاسل الزمنية، ومن أجل نمذجة المسائل من هذا النوع. سنبين في هذا القسم بأن المنظومة المقترحة في هذا الفصل يمكن أيضاً أن تنفذ بنجاح استخلاص المعرفة من RANNs. وتُطرح مسألة استخلاص القواعد من ANNs ذات البنى الهندسية التكرارية كعقبة إضافية، كما وُصّفت تلك ANNs بقدرتها الهائلة على التمثيل والمعرفة الموزعة بين اتصالاتها. ويمكن أن يُطبق هذا بشكل محدد على المسائل الزمنية والديناميكية. إن المسألة التي ستحل هي توقع سلسلة زمنية مخبرية عشوائية كلاسيكية: سلسلة Mackey - Glass (Mackey, 1977). تظهر النتائج اللاحقة بأن القواعد التي سيُحصل عليها من هذه ANN، يجب أن تدمج آليات لمعالجة القيم الزمنية. لذا، سوف تُستخدم عقد غير طرفية، تمثل عمليات رياضية ومثلثية، سويةً مع متغيرات دخل من n لحظة سابقة (Xn). غالبية حالات السلاسل الزمنية هذه هي بنى ذات دخل وحيد وخرج وحيد. يُوافق الدخل قيمة عددية في اللحظة t بينما يكون خرج المنظومة هو توقع القيمة العددية في اللحظة 1 + t. معادلة Mackey - Glass هي معادلة تأخير تفاضلية عادية (3).

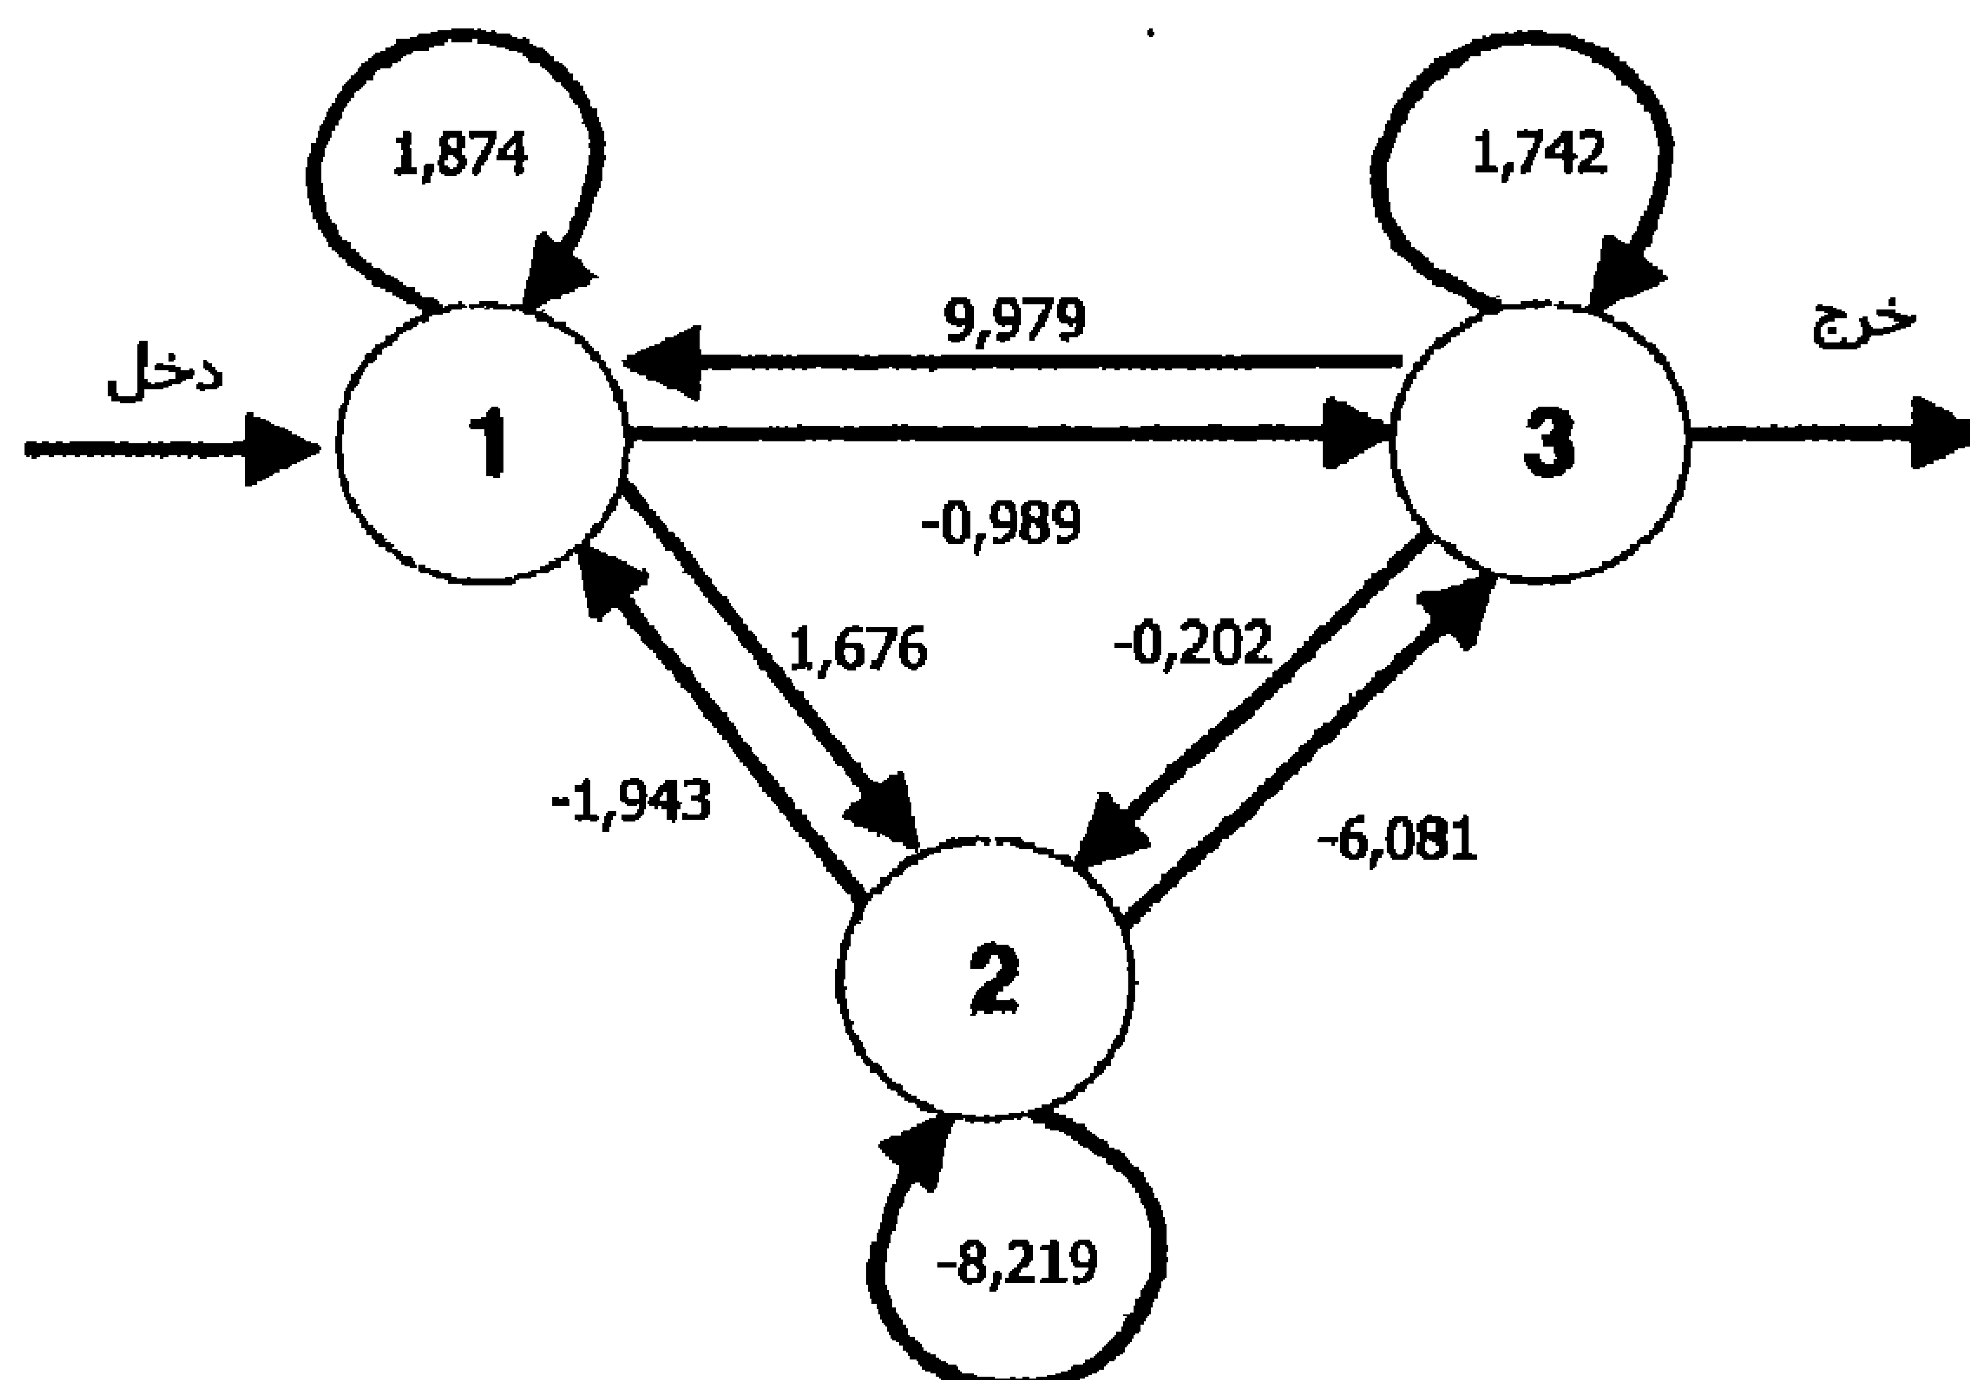
$$\frac{dX}{dt} = \frac{ax(t-\tau)}{1+x^{c}(t-\tau)} - b\times(t) \qquad (3)$$

باختيار 30 = τ، تصبح المعادلة عشوائية. وتكون التوقعات قصيرة الأمد هي فقط القابلة للتنفيذ. بإجراء تكامل المعادلة (3) في المجال [t, t + τt] نحصل على التالي:

$$X(t+\Delta t)=\frac{2-b\Delta t}{2+b\Delta t}X(t)+\frac{\alpha\Delta t}{2+b\Delta t}\left[\frac{X(t+\Delta t-\tau)}{1+X^{C}(t+\Delta t-\tau}+\frac{X(t-\tau)}{1+X^{C}(t-\tau)}\right]$$

الخطوة الأولى هي الحصول على RANN التي تحاكي سلوك السلسلة الزمنية. تمتلك RANN التي استخدمناها ثلاثة عصبونات بتابع تفعيل ظلي زائدي المقطع وباتصالات بينية كاملة. توافق ملفات التدريب المستخدمة لأول 200 قيمة من السلسلة الزمنية (الشكل 5). يبين (الشكل 4) RANN الناتجة من عملية التدريب، والتي أنتجت متوسط مربع الخطأ الأقل (MSE = 0.00072).

الشكل(4) *RANN التي تحاكي تابع Mackey - Glass*



عندما حصلنا على RANN، حاولنا الحصول على القواعد والتعابير التي تدير أداءها الوظيفي باستخدام ارتداد رمزي. في هذه الحالة، استخدمنا ملف الاختبار الحاوي على القيم 1000 الأولى من السلسلة الزمنية. نُقلت هذه القيم الـــ 1000 إلى RANN، التي حصلت على المخرجات الموافقة. باستخدام ملف الدخل - الخرج قمنا بتشغيل خوارزمية GP. جربنا توليفات مختلفة من عناصر الطرفية والوظائفية وبارامترات GP. وقد تم استخدام التالي:

- توابع حسابية: +، -، *، % (تقسيم محمي).
- ثوابت: 10 قيم عشوائية في المجال [0، 1].
- خوارزمية الاختيار: بطولة (سلسلة مباريات).

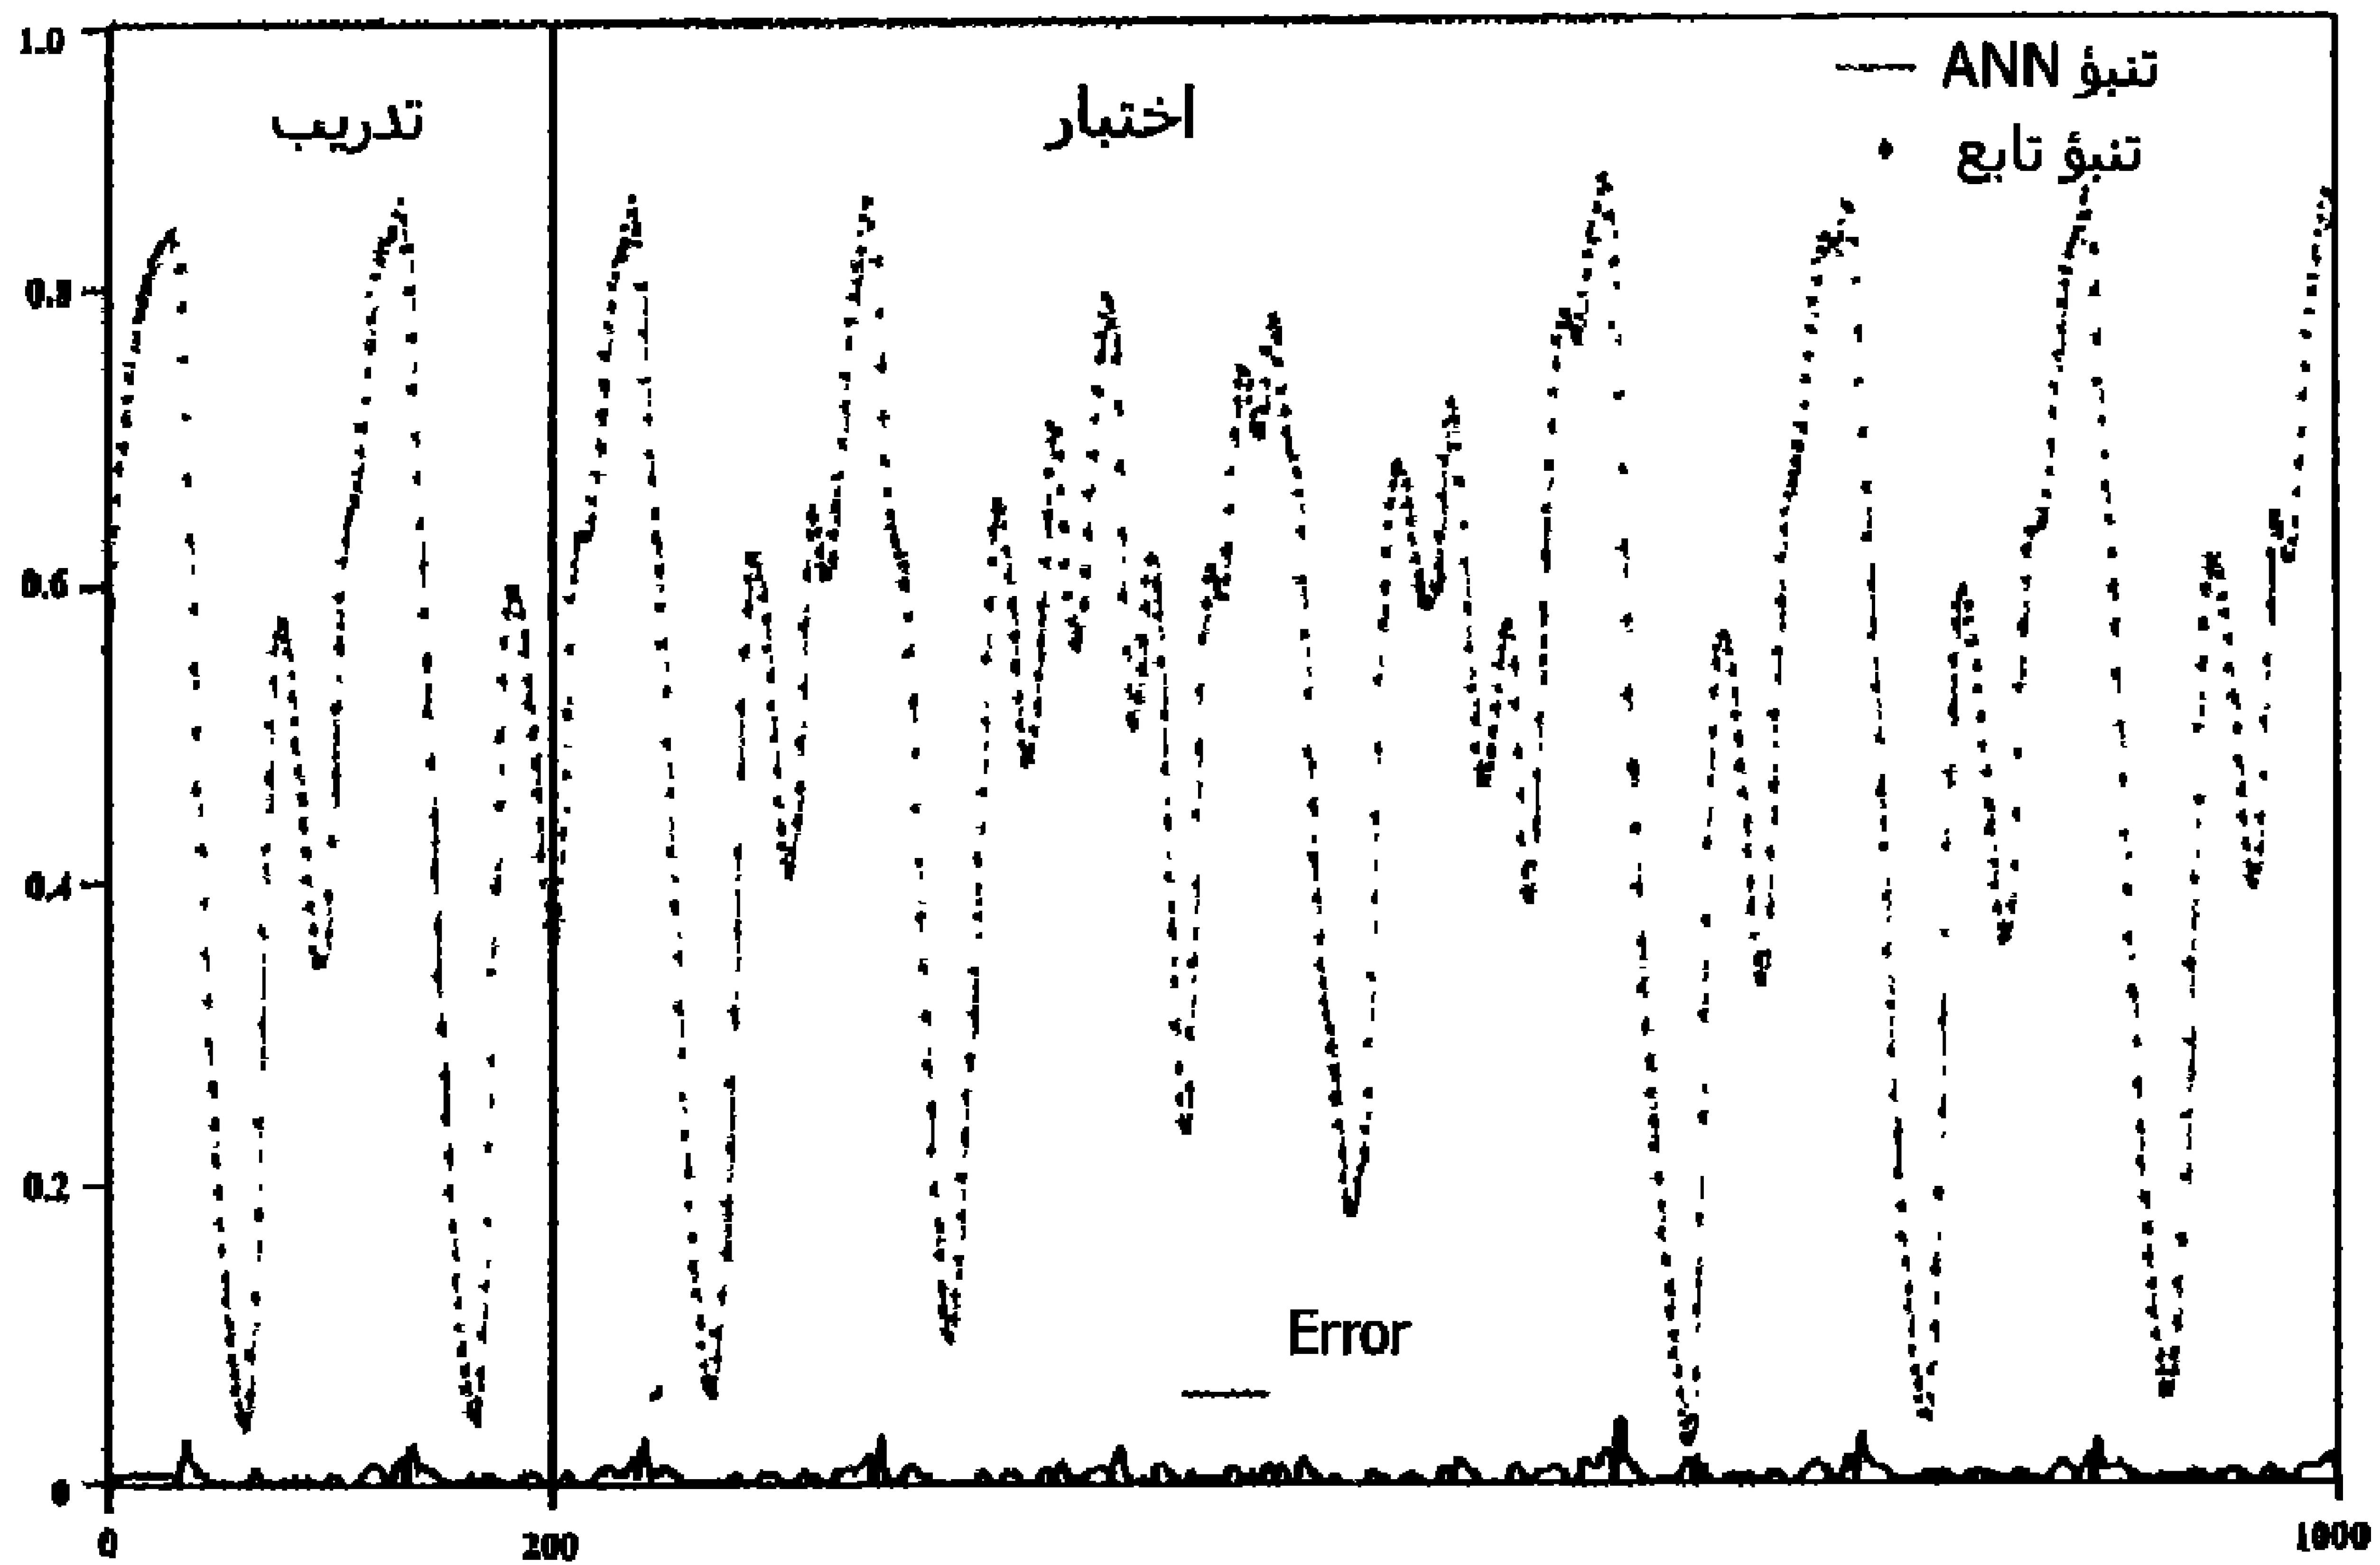
- معدل التصالب: 95 %.
- مستوي الاقتصاد: 0.0001
- متغيرات: X_{n-3}، X_{n-2}، X_{n-1}، X_n
- حجم المجتمع: 1000 سلسلة فردية.
- معدل الطفرة: 4 %.

أيضاً، استخدمت الاستراتيجية الانتخابية، التي لا تسمح بخسارة السلسلة الفردية الأفضل. القاعدة المُعبر عنها كتابع رياضي هي كالتالي:

$$(X_n * ((((((X_n * (X_n * X_{n-2})) \% X_{n-2}) * (((0.9834 * (((((X_n * (X_{n-2} \% X_{n-3})) * X_{n-3}) * X_{n-3}) \% X_{n-3}) \% (X_n \% X_{n-3}))) \% X_{n-3}) \% ((X_{n-2} * X_{n-2}) \% X_{n-3}))) \% X_{n-3}) * X_{n-2}) \% X_{n-2})) \% ((X_n * X_{n-2}) \% X_{n-3}) * 0.9834))$$

يحصل هذا التابع على قيمة ملاءمة (مُسوّاة) على الـ 1000 قيمة المنتجة من قبل RANN مقدارها 0.0029. يقارن (الشكل 5) القيم المنتجة بتنبؤ التابع وتنبؤ RANN.

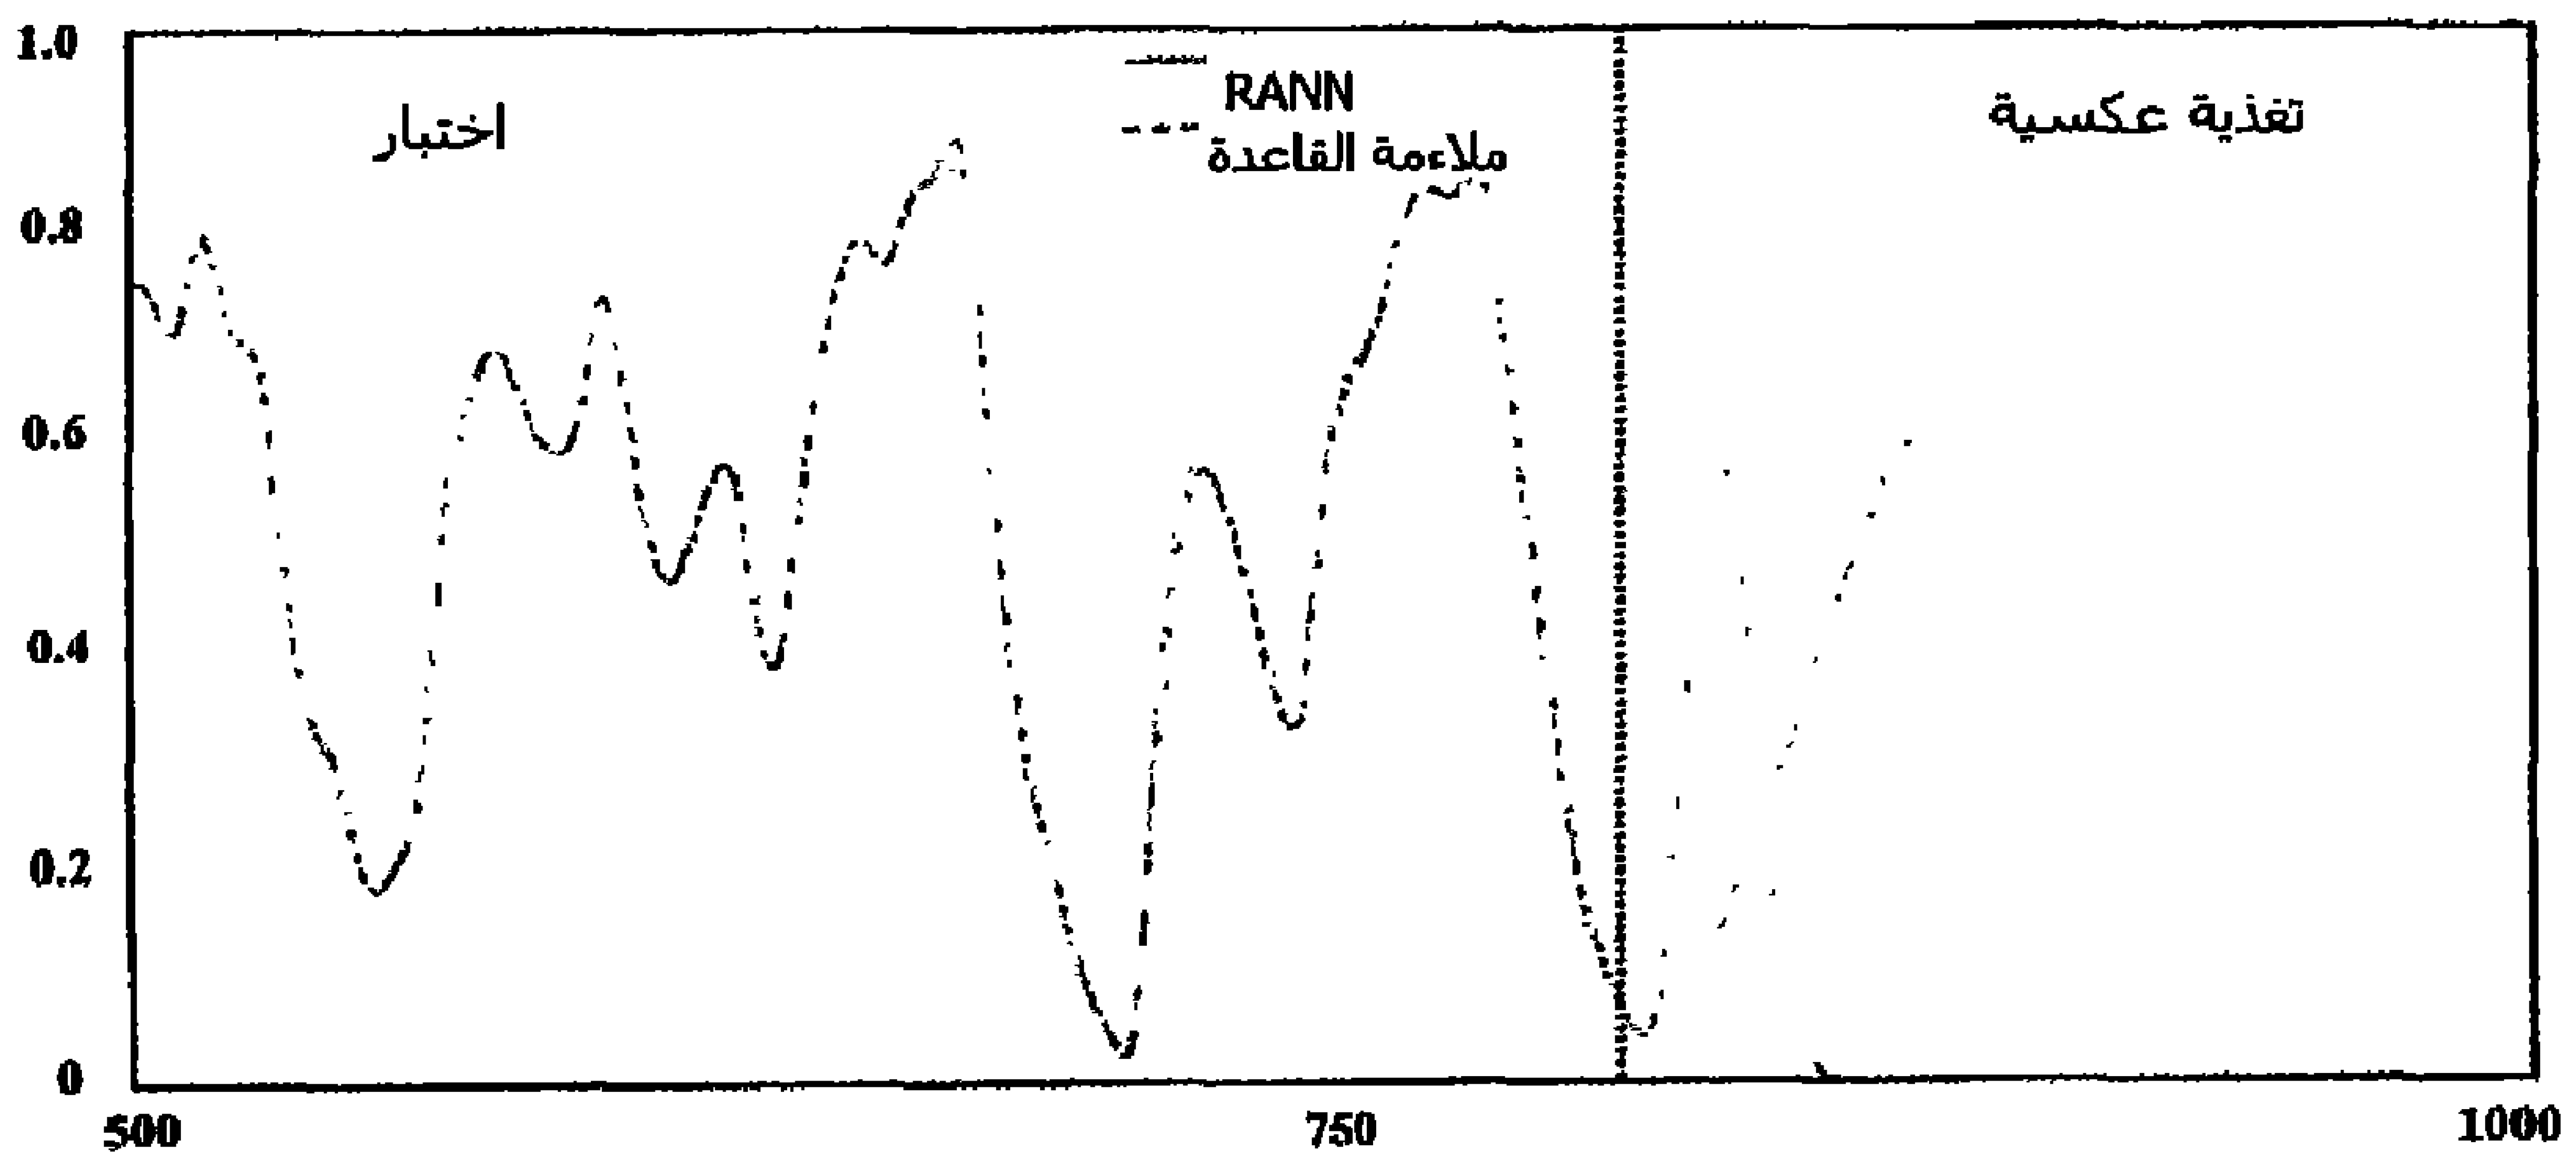
الشكل (5) *مقارنة بين تنبؤ RANN وتنبؤ التابع*



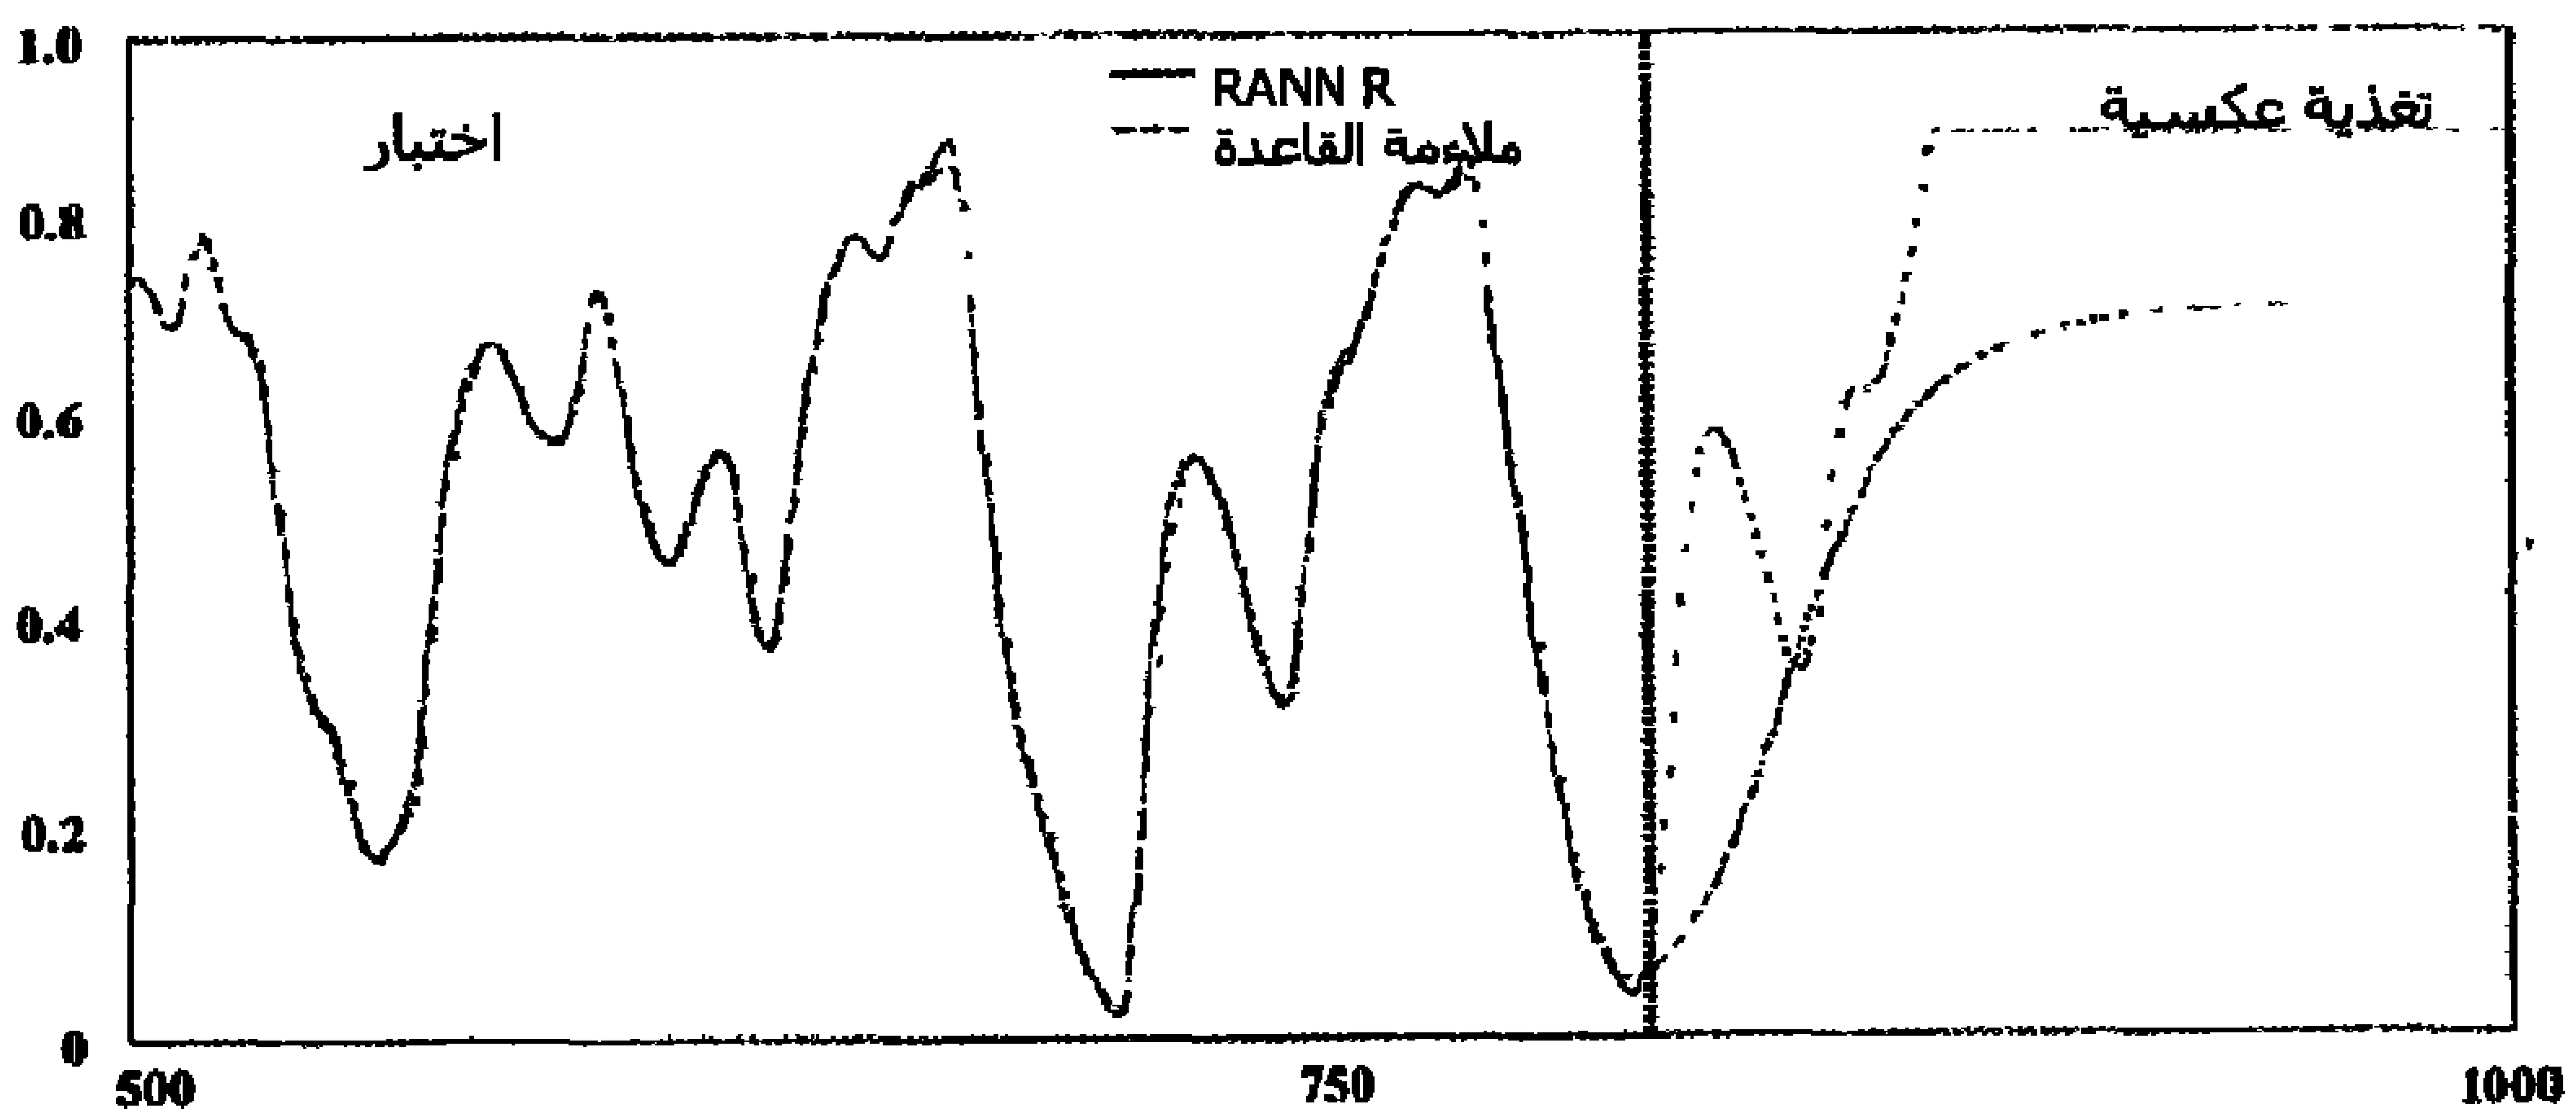
إذا أُخذ (الشكل 5) بالاعتبار يمكن أن يُستنتج بأن القواعد تضبط التوقع قصير الأمد لـ ANN بطريقة مقنعة. ولكن ما الذي يحدث في حالة التنبؤ طويل الأمد؟ للتحقق من ذلك، من الضروري استخدام التغذية العكسية للمخرجات المكتسبة في اللحظة السابقة تماماً كقيم دخل للقاعدة.

تظهر النتائج بشكل واضح كم يختلف سلوك القاعدة عن سلوك ANN. فبينما تتجه ANN بشكل طبيعي نحو القيم الوسطى للسلسلة، فإن مخرجات القواعد ستتجه نحو قيمة واحدة أو أخرى اعتماداً على الاتجاه السابق - بمعنى أنه هل كانت السلسلة على ميل تصاعدي أم تنازلي في اللحظة التي تبدأ التغذية العكسية للمخرجات. فإذا كان الميل تنازلياً (انظر الشكل 6)، فإن القيم المزودة من قبل القواعد تتجه نحو 0 أو ∞-، في حين إذا كان الميل تصاعدياً (انظر الشكل 7)، تتجه القيم نحو 0 أو ∞+، هنا يمكن ملاحظة أن الخرج المزود من قبل القواعد يبدأ بالزيادة بطريقة غير محدودة (تحديداً في اللحظة 1000 وتكون قيمته هي 1.94×10^{10}).

الشكل (6) *سلسلة Mackey-Glass: الضبط (التسوية) المكتسب بـ 200 تغذية عكسية*



الشكل (7) *سلسلة Mackey-Glass: الضبط المُكتسب بـ 150 تغذية عكسية*



لذا، يبدو أمراً واضحاً بأن القاعدة المستخلصة لم تقبض على قدرة تعميم الـ RANN بنجاح كما هو مطلوب. بغية حل هذه المشكلة، يجب أن تُنفذ عملية استخلاص القاعدة من جديد. ولكن هذه المرة مع التحسين المُشار إليه. في هذه الحالة، سيتم الحصول على الملاءمة للقاعدة اعتماداً على التغذية العكسية لمخرجاتها، وليس على القيم الحقيقية للسلسلة نفسها أو المخرجات المزودة من قبل RANN. يتضمن المخطط المستخدم لتشكيل عملية استخلاص القاعدة القيم 200 الأولى من السلسلة و20 قيمة عشوائية (لمسح الذاكرة "الداخلية لـ RANN) و60 مدخل تغذية عكسية باستخدام التشكيل البارامتري التالي:

- نسبة الأنماط الجديدة المئوية: 40 % (ما مجموعه 200 + 80 نمط).
- احتمال التغيير: 20 %
- الخطأ الأدنى للبقاء: 0.01
- عدد مخارج التغذية العكسية: بين 10 و60.

أولاً – أُستخدمت 10 قيم من أجل البارامتر الأخير، وبينما كانت الخوارزمية تُنفّذ، تم تعديلها حتى أُنهيت بـ 60 قيمة. ويكمن السبب لتنفيذها بهذا الأسلوب، في أنه إذا بدأت العملية بقيمة عالية، فإن سلوك RANN سيتجه نحو معدل القيم السابقة الأخيرة، وكنتيجة لذلك، تصبح عملية الاستخلاص ملتصقة في حد أدنى محلي متوضع في القاعدة: الخرج = X_n (الخرج هو قيمة الدخل ← $X_{n+1} = X_n$). لذا، بغية منع حدوث ذلك، تم تفضيل الخلق العشوائي للقيم جديدة على مخارج التغذية العكسية، وعندما يتم تجاوز الحد الأدنى المحلي تُفضل مخارج التغذية العكسية. يجب تنفيذ ذلك يدوياً، طالما أن الخوارزمية لا تعرف إن كانت قد وقعت في حد أدنى محلي أم لا، وبملاحظة نوع القواعد المكتسبة يُعاد ضبط البارامترات مباشرةً.

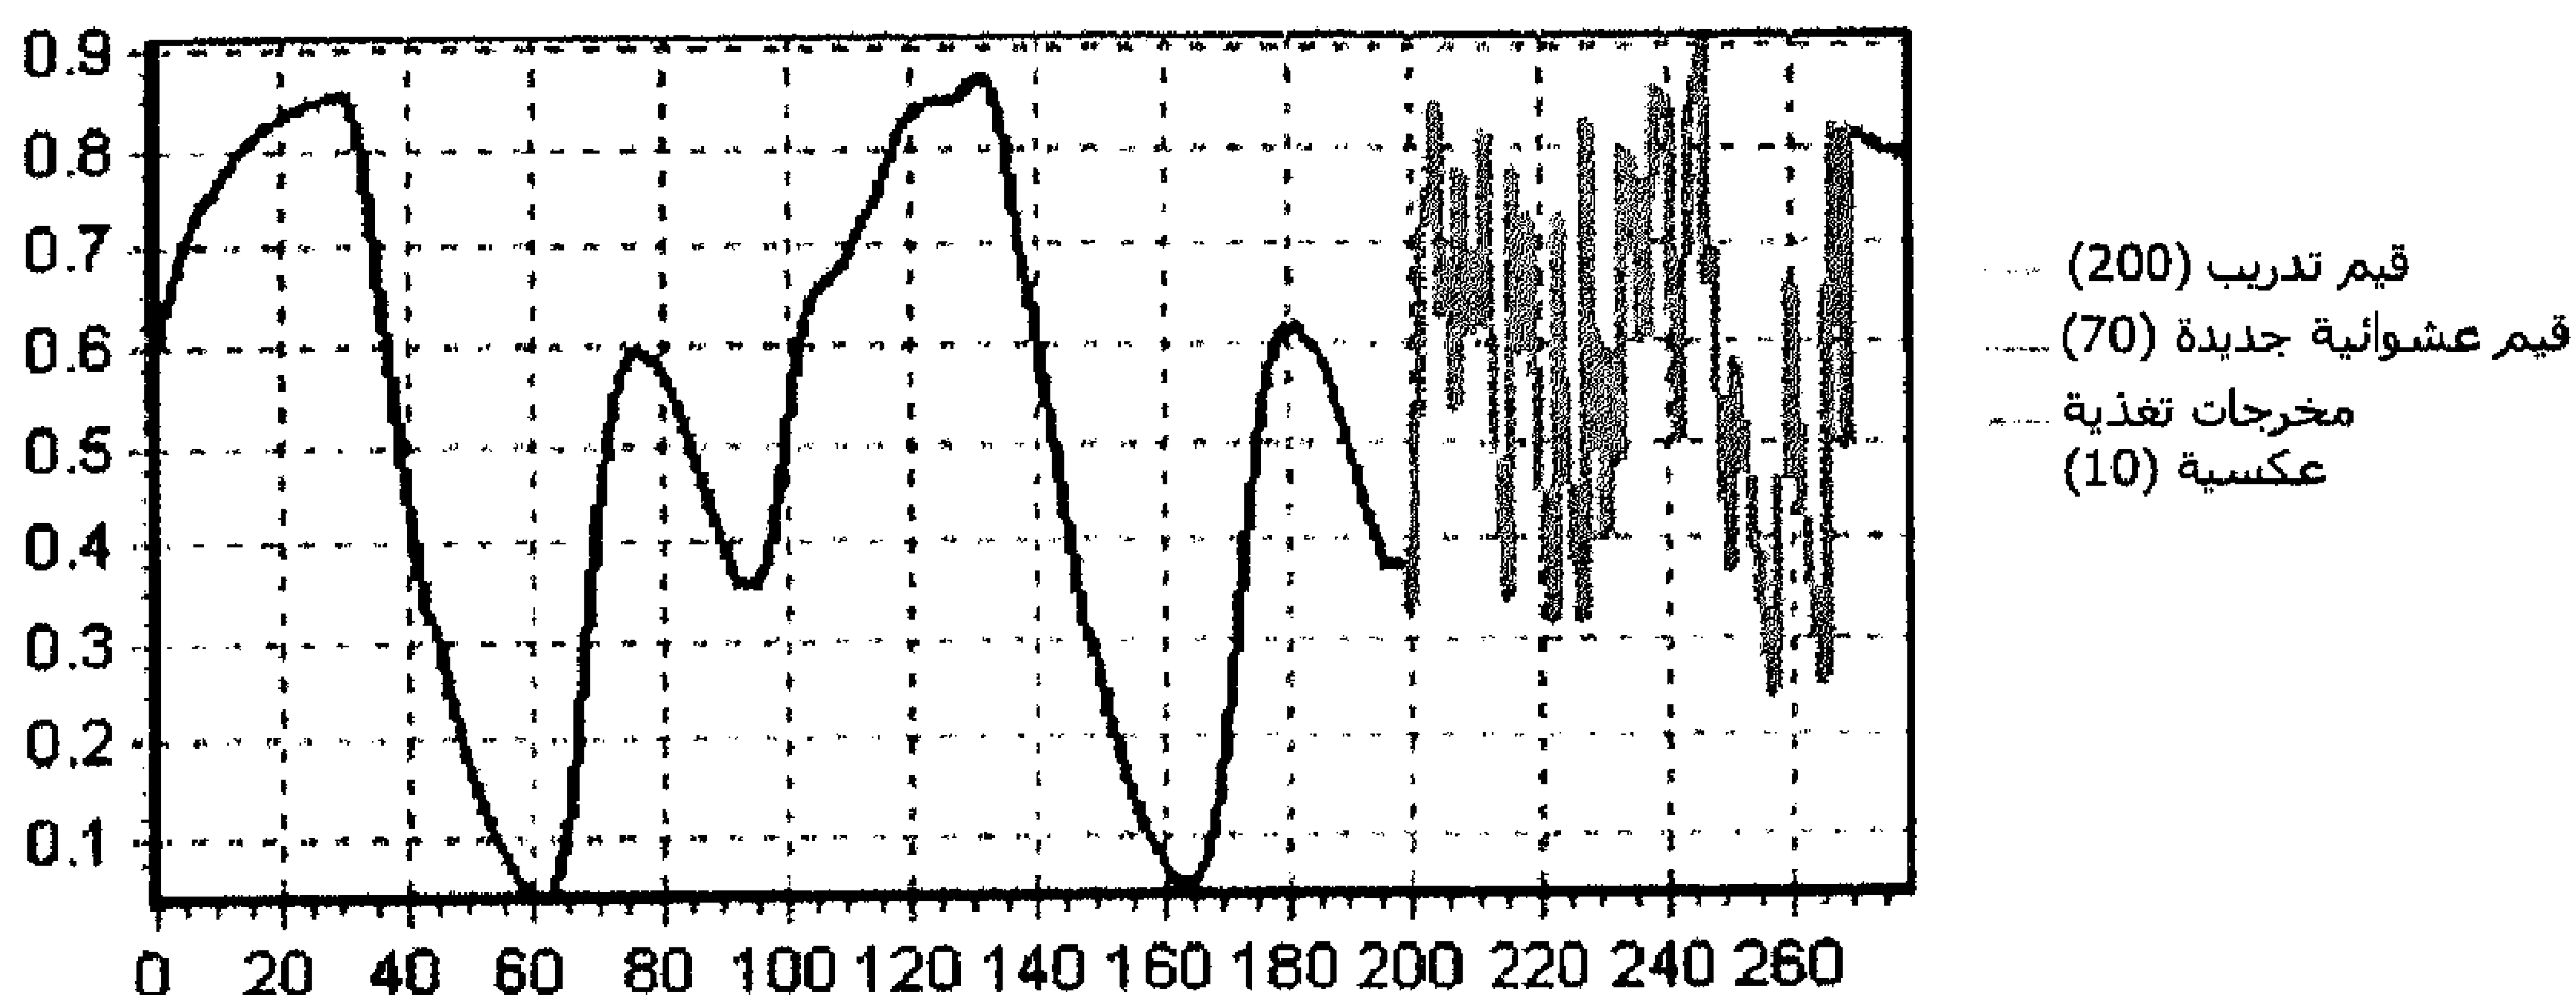
في حالة البارامترات من أجل خوارزمية الاستخلاص، تُستخدم نفس البارامترات كما في الحالة السابقة، طالما أن نوع المشكلة هو نفسه، وأيضاً التعابير المكتسبة والنتائج التي تعطيها قد تُقارن على نحو ذي مغزى أكثر في نفس حالة السيناريوهات.

يظهر (الشكل 8) مثالاً لخلق القيم الابتدائية المكتسبة من قبل خوارزمية خلق ديناميكي للأمثلة.

بعد يوم واحد و4 ساعات من التنفيذ، تم الحصول على المعادلة المثالية كنتيجة لعملية الاستخلاص:

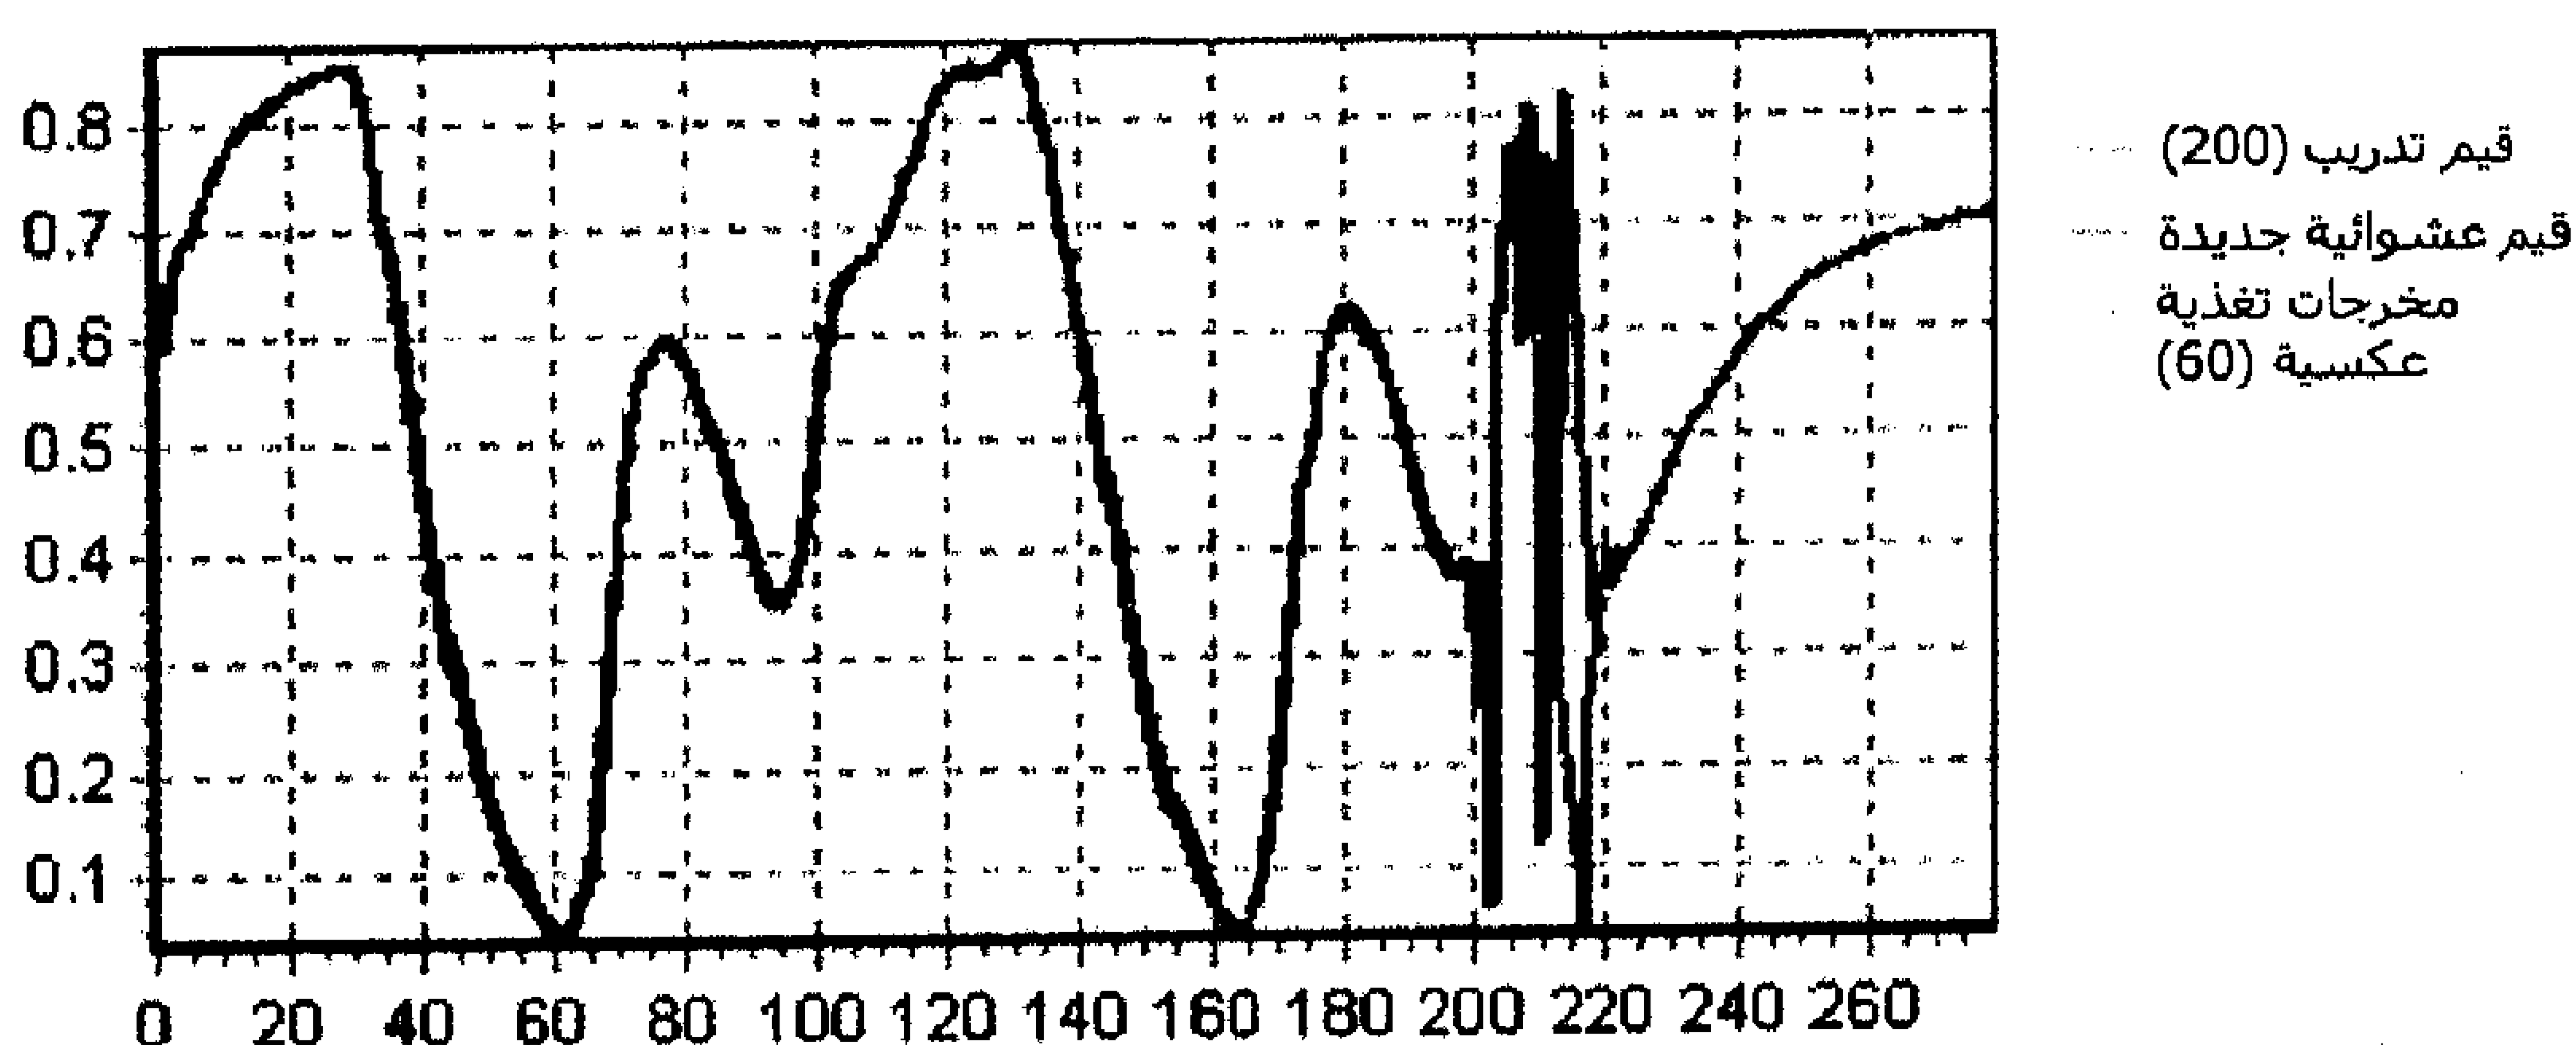
$$(((((X_{n-1} - X_{n-3}) * (- ((X_n * X_n) - 0.7554))) * (-2.3241)) * (- 0.2474)) + X_n) - ((((X_{n-1} * (- ((X_n * X_n) - 0.7544))) * (- 2.3241)) * (- 0.2474)) * ((((X_n - (- 0.2457)) - X_{n-2}) * (X_{n-3} + ((X_n * X_n) - 0.7554))) \% ((X_{n-3} - (0.2979 * X_{n-4})) \% 0.0752))))$$

***الشكل (8)** نمط التعلّم المُخلّق من قبل خوارزمية خلق الأمثلة*



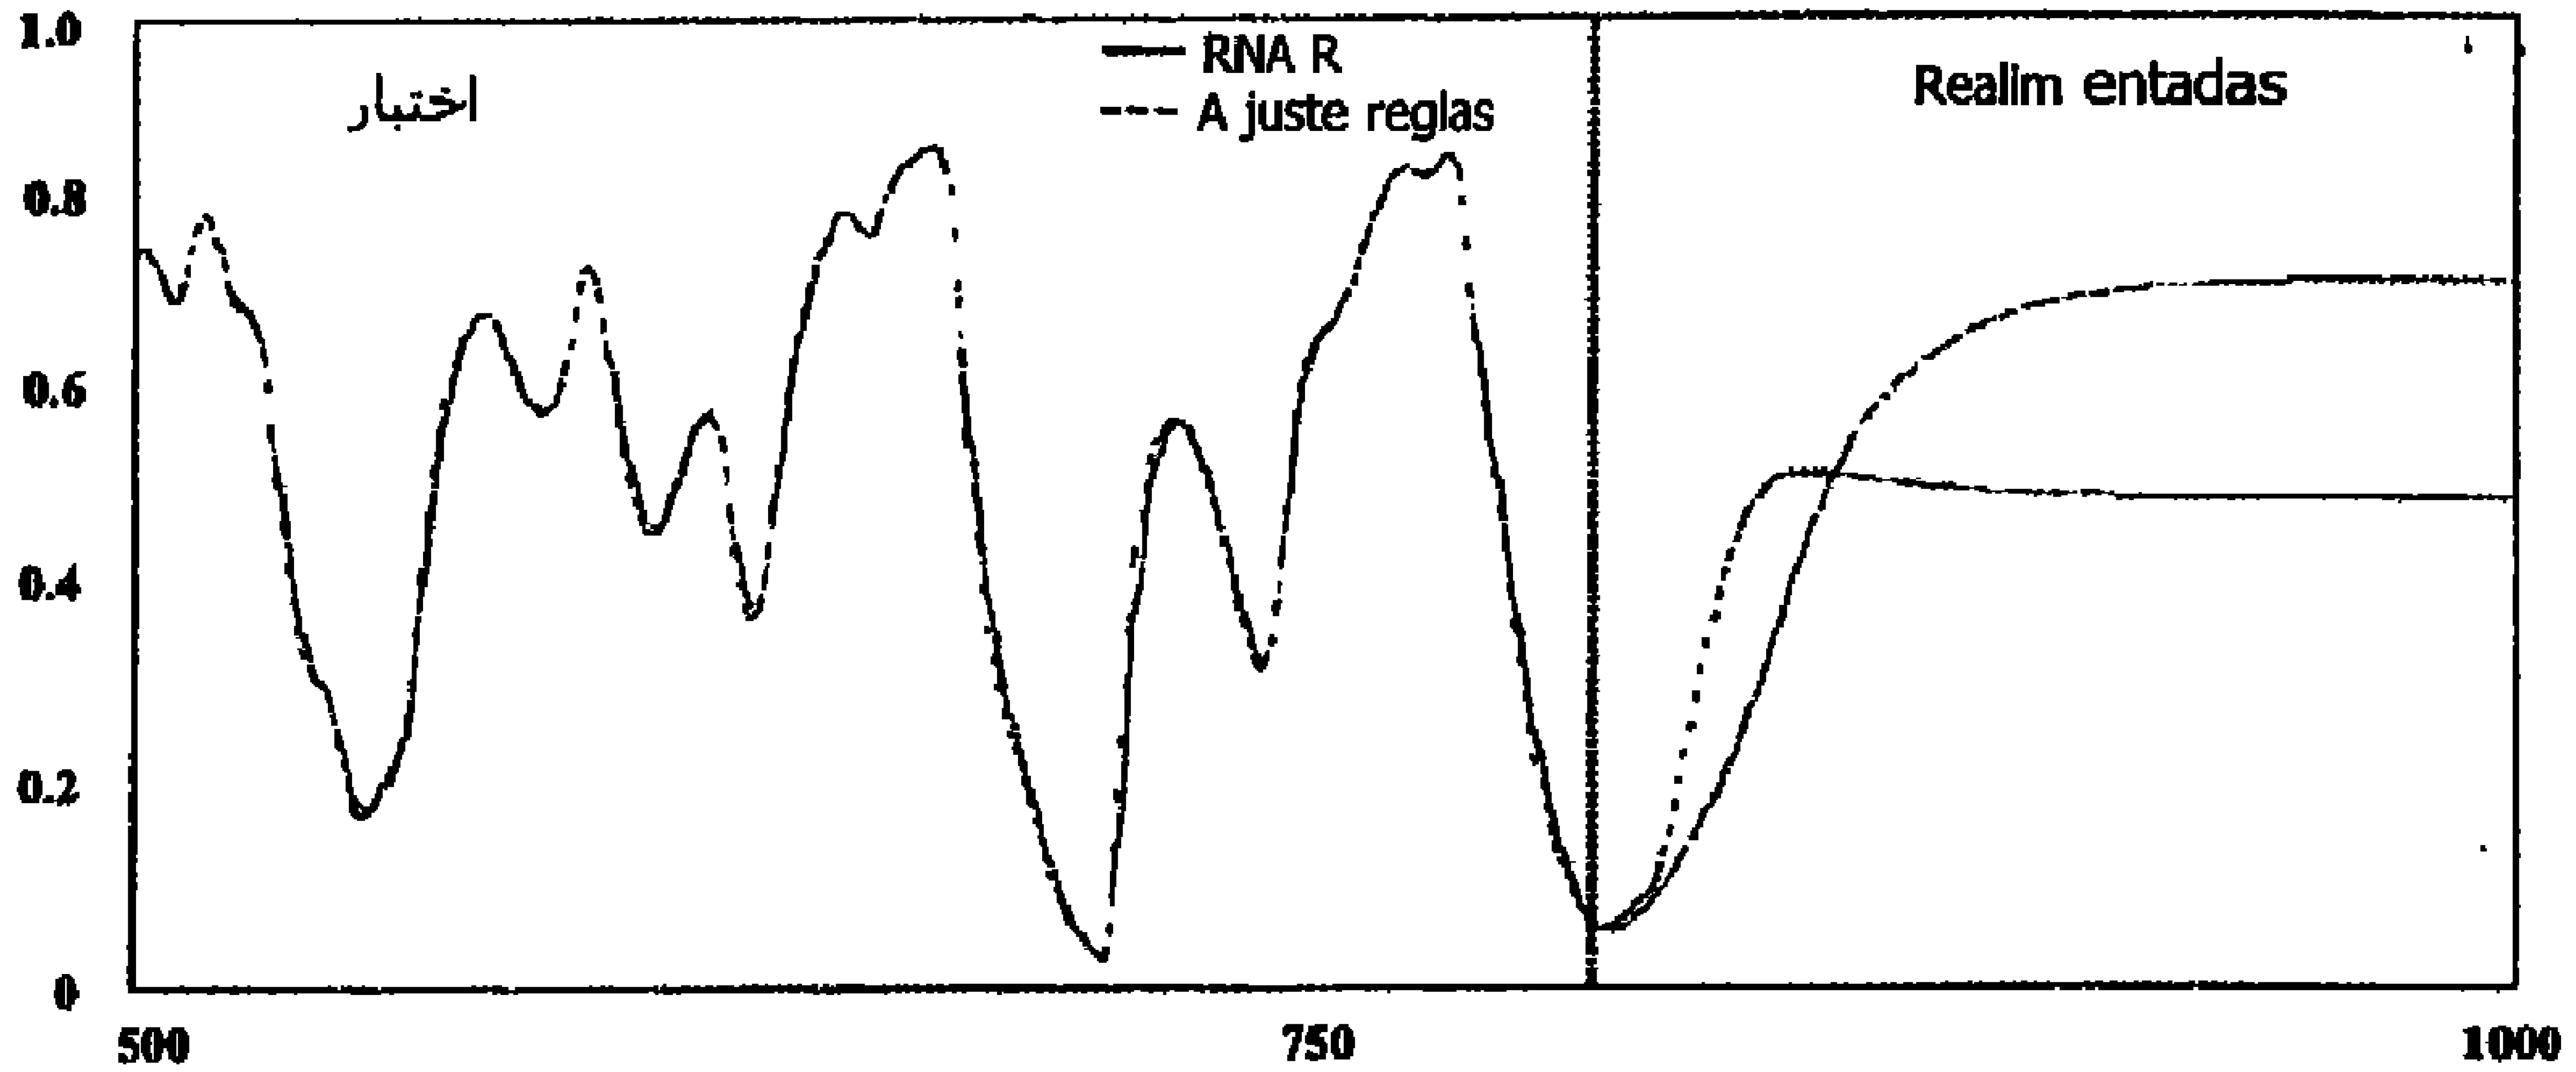
يظهر (الشكل 9) الضبط المكتسب من المعادلة السابقة بأنماط تعلّم مُشكّلة كـــ 200 قيمة تدريب و20 قيمة عشوائية و60 مدخل تغذية عكسية. وهو يظهر بتفصيل أكبر سلوك RANN، عندما تمت المواجهة بالتغذية العكسية لمخرجاها.

***الشكل (9)** الضبط المُكتسب*



في (الشكل 9)، يمكن أن نبدأ بملاحظة كيف تتصرف هذه القاعدة من أجل تنبؤ طويل الأمد. يمكننا هنا مشاهدة كيف تعطي نواتج التعبير مظهراً جانبياً ضمن المجال [0، 1]، الذي هو نفس المقدم بالإشارة الأصلية. علاوة على ذلك، كما هو مبين في (الشكل 10)، فإن سلوك الخرج المزود من قبل القواعد مشابه جداً لذلك المزود من قبل RANN بمنطقة ابتدائية ذات قيم مرتفعة، التي تستقر بعد ذلك باتجاه القيم المتوسطة للإشارة، وبتوقع مرضٍ عالٍ في اللحظات الأولية التي يوجد فيها تغذية عكسية للخرج.

الشكل (10) سلسلة Mackey-Glass: الضبط المكتسب بخوارزمية الاستخلاص



الاستنتاجات

كما ذُكر في مقدمة هذا الفصل، يجب على أي نظام يحاول استخلاص القواعد من المعرفة المخزنة في ANN أن يستجيب لسلسلة من الميزات: أن يكون مستقلاً عن البنية الهندسية للشبكة، ومستقلاً عن خوارزمية التعلّم المستخدمة، ويمتلك مستوى مناسباً للتصحيح، ويُولّد قواعد معبرة جداً.

بفضل الاقتراح المقدم هنا، من الممكن التعامل مع ANN كأنها صندوق أسود باستخدام تقنية EC مثل GP، بأخذ فقط المدخلات والمخرجات المُنتجة من قبل ANN. بهذا الأسلوب، من الممكن الاستجابة للمتطلبات بأن تكون البنية الهندسية وخوارزمية التعلّم مستقلتين.

إضافة إلى ذلك، تقارب القواعد المُولّدة الأداء الوظيفي لـــ ANN بنفس الأسلوب كقيمة ضبط منتجة من قبل خوارزمية الاستخلاص (GP)، الأمر الذي يعني، بأن التصحيح مضمون. علاوة على ذلك، تزود هذه القواعد قيمة ذات معنى لأشجار التعابير التي تُصنّف بها السلاسل الفردية الوراثية لخوارزمية الاستخلاص.

لذا، يمكن القول بأن خوارزميات الاستخلاص المعتمدة على تقنيات EC تلائم المتطلبات المطلوبة لخوارزميات من هذا النوع، بالإضافة إلى إعطاء نتائج مماثلة إن لم تكن أفضل من تلك المزودة من قبل الطرق، التي تكون أكثر تحديداً ومعتمدة على المسألة.

تُقدّم نتائج الاختبارات المُنفذة كدعم لهذه الأفكار. المثال المختار (سلسلة Mackey-Glass) مدروس في المراجع والمنشورات في مجالات علمية مختلفة (رياضية، إحصائية... الخ)، وهي معقدة بما فيه الكفاية لكي تُحدد فيما إذا كانت خوارزميات الاستخلاص فعالة في تنفيذ

مهامها. تظهر دراسة مفصلة عن هذه النتائج كيف تحصل القواعد المكتسبة من قبل الخوارزمية المقترحة على نتائج جيدة – إن لم تكن أفضل – كالعديد من الطرق الأخرى المصممة خصيصاً لكلٍّ من المسائل المقترحة.

علاوة على ذلك، يمكننا أن نستنتج من النتائج المكتسبة من اكتشاف قدرة التعميم، بأنه تم إنجاز محاكاة دقيقة لسلوك ANN فيما يتعلق بالتوليفات الممكنة للقيم، التي قد تحدث في المدخلات. وبالتالي، حصلنا على دقة عالية لسلوك ANN مبينة في معدل النجاح العالي لاستخلاص القواعد من ANNs. كما يمكننا التصريح، بأنه تم الحصول على المعرفة المعززة بـــ ANN في أسلوب واضح وصريح من وجهة نظر الإنسان. كما يمكننا أيضاً التعبير عن قدرة تعميم ANN باستخدام قاعدة رمزية.

الدراسات المستقبلة

سيكون التطوير المستقبلي هو تحليل البارامترات المختلفة، التي تتدخل في الأداء الوظيفي الصحيح للخوارزمية اعتماداً على نوع المسألة المحلولة بـــ ANN. يجب ألا تُعامل ANN كصندوق أسود بل كصندوق رمادي، يكون فيه – على سبيل المثال – تابع تفعيل ANN معلوماً ومدمجاً. كأحد المعاملات الرياضية لـــ GP، والذي بتحليله أيضاً تُستخلص القواعد بواسطة هذا المعامل.

بغية تسريع عملية استخلاص القواعد، يمكن أن تُستخدم شبكة من عدة حواسيب بحيث ينفذ البحث في أسلوب موزع ومتلاقٍ بتبادل القواعد (أشجار جزئية) بين بعضها البعض.

المراجع

Andrews, R., Cable, R., Diederich, J., Geva, S., Golea, M., Hayward, R., Ho-Stuart, C., & Tickle A.B. (1996). An evaluation and comparison of techniques for extracting and refining rules from artificial neural networks. Queensland University of Technology, Neurocomputing Research Centre. QUT NRC Technical report.

Andrews, R., Diederich, J., & Tickle, A. (1995). A survey and critique of techniques for extracting rules from trained artificial neural networks. Knowledge Based Systems, 8,373-389.

Andrews, R., & Geva, S. (1994). Rule extraction from a constrained error backpropagation MLP. Proceedings of the Australian Conference on Neural Networks, Brisbane, Queensland (pp. 9-12),

Benítez, J.M., Castro, J.L., & Requena, I. (1997). Are artificial neural networks black boxes? IEEE Transactions on Neural Networks, 8(5), 1156-1164.

Blake, C.L., & Mertz ,C.J. (1998). UCI repository of machine learning databases. University of California, Department of Information and Computer Science. Retrieved from www-old.ics.uci.edu/pub/machine-learning-databases

Bonarini,A.(1996). Evolutionary learning of fuzzy rules: Competition and cooperation. In W. Pedrycz (Ed.), Fuzzy modelling: Paradigms and practice. Norwell, MA: Kluwer Academic Press.

Browne,C.,Düntsch, I.,& Gediga, G.(1998). IRIS revisited: A comparison of discriminant and enhanced rough set data analysis. In Rough sets in knowledge discovery (vol. 2, pp. 345-368). Heidelberg: Physica Verlag.

Buckley,J.J.,Hayashi,Y.,& Czogala, E. (1993). On the equivalence of neural nets and fuzzy expert systems. Fuzzy Sets Systems, 53, 29-134.

Chalup, S., Hayward, R., & Diedrich, J. (1998). Rule extraction from artificial neural networks trained on elementary number classification task. Queensland University of Technology, Neurocomputing Research Centre. QUT NRC Technical report.

Cramer,N.L. (1985). A representation for the adaptive generation of simple sequential programs. Grefenstette: Proceedings of First International Conference on Genetic Algorithms.

Craven, M.W. (1996). Extracting comprehensible models from trained neural networks. Ph.D. thesis. University of Wisconsin, Madison.

Craven, M.W., & Shavlik, J.W. (1996). Extracting tree-structured representations of trained networks. Advances in neural information processing systems (vol. 8). Cambridge, MA: MIT Press.

Duch, W., Adamczak, R., & Grbczewski, K. (2001). A new methodology of extraction, optimisation and application of crisp and fuzzy logical rules. IEEE Transactions on Neural Networks, 12, 277-306.

Engelbrecht, A.P., Rouwhorst, S.E.,& Schoeman,L. (2001). A building block approach to genetic programming for rule discovery. In R. Abbass & C. Newton (Eds.), Data mining: A heuristic approach. Hershey, PA: Idea Group Publishing.

Fayyad, U., Piatetsky-Shapiro, G., Smyth, P., & Uthurusamy, R. (1996). Advances in knowledge discovery and data mining. AAAI/MIT Press.

Fisher, R.A. (1936). The use of multiple measurements in taxonomic problems. Annals of Eugenics,7, 179-188.

Friedberg, R.M. (1958). A learning machine: Part I. IBM Journal of Research and Development, 2(1), 2-13.

Friedberg, R.M., Dunham, B., & North, J.H. (1959). A learning machine: Part II. IBM Journal of Research and Development, 3(3), 282-287.

Fujiki, C. (1987). Using the genetic algorithm to generate lisp source code to solve the prisoner's dilemma. International Conf on Gas, 236-240.

Halgamuge, S.K., & Glesner, M. (1994) Neural networks in designing fuzzy systems for real world applications. Fuzzy Sets and Systems, 65, 1-12.

Jagielska, I., Matthews, C., & Whitfort, T. (1996). The application of neural networks, fuzzy logic, genetic algorithms and rough sets to automated knowledge acquisition. 4th Int. Conf on Soft Computing, IIZUKA '96, Japan (vol. 2, pp. 565-569).

Jang, J.,& Sun, C. (1992). Functional equivalence between radial basis function networks and fuzzy inference systems. IEEE Transactions on Neural Networks, 4, 156-158.

Jankowski, N., & Kadirkamanathan, V. (1997). Statistical control of RBF-like networks for classification. 7th International Conference on Artificial Neural Networks, Lausanne, Switzerland (pp. 385-390).

Kasabov, N. (1996). Foundations of neural networks, fuzzy systems and knowledge engineering. Cambridge, MA: MIT Press.

Keedwell, E., Narayanan, A., & Savic, D. (2000). Creating rules from trained neural networks using genetic algorithms. International Journal of Computers, Systems and Signals (IJCSS), I (I), 30-42.

Koza, J. (1992). Genetic programming: On the programming of computers by means of natural selection. Cambridge, MA: MIT Press.

Koza, J. (1994). Genetic programming II: Automatic discovery of reusable programs (complex adaptive systems). Cambridge, MA: The MIT Press.

Koza, J., Bennett, F.H., Andre, D., & Keane, M.A. (1999). Genetic programming III: Darwinian invention and problem solving. Morgan Kauffman.

Mackey,M.,& Glass, L. (1977). Oscillation and chaos in physiological control systems. Science, 197, 287.

Martínez, A., & Goddard, J. (2001). Definición de una red neuronal para clasificación por medio de un programa evolutivo. Revista Mexicana de Ingeniería Biomedica, 22(1),4-11.

Montana, D.J. (1995). Strongly typed genetic programming. In Evolutionary computation (pp. 199-200). Cambridge, MA: MIT Press.

Nauck, D., Nauck, U., & Kruse, R. (1996). Generating classification rules with the neuro-fuzzy system NEFCLASS. Proceedings of Biennal Conference of the North American Fuzzy Information Processing Society (NAFIPS'96), Berkeley, CA.

Pop, E., Hayward, R., & Diederich, J. (1994). RULENEG: Extracting rules from a trained ANN by stepwise negation. Queensland University of Technology, Neurocomputing Research Centre. QUTNRC Technical report.

Rabuñal, J.R. (1999). Entrenamiento de Redes de Neuronas Artificiales mediante Algoritmos Genéticos. Graduate thesis, Facullad de Informática, Universidade da Coruña.

Rabuñal, J.R., Dorado, J., Pazos, A., Pereira, J., & Rivero, D. (2004). A new approach to the extraction of ANN rules and to their generalization capacity through GP. Neural Computation, 16(7), 1483-1524.

Shang, N., & Breiman, L. (1996). Distribution based trees are more accurate. International Conference on Neural Information Processing (vol. 1, pp. 133-138). Hong Kong.

Ster,B.,& Dobnikar, A. (1996).Neural networks in medical diagnosis: Comparaison with other methods. Proceedings of the International Conference on Engineering Applications of Neural Networks, EANN'96 (pp. 427-430).

Thrun, S. (1995). Extracting rules from networks with distributed representations. In G. Tesauro, D. Touretzky, & T. Leens (Eds.), Advances in neural information processing systems (NIPS) (vol. 7). Cambridge, MA: MIT Press.

Tickle, A.B., Andrews, R., Golea, M., & Diederich, J. (1998). The truth will come to light: Directions and challenges in extracting the knowledge embedded within trained artificial neural networks. IEEE Transaction on Neural Networks, 9(6), 1057-1068.

Tickle, A.B.,Orlowski, M.,&DiedrichJ. (1996). DEDEC; Amethodology for exracting rules from trained artificial neural networks. Queensland University of Technology, Neurocomputing Research Centre. QUT NRC Technical report.

Towell, G., & Shavlik, J.W. (1994). Knowledge-based artificial neural networks. Artificial Intelligence,70, 119-165.

Visser, U., Tickle, A., Hayward, R., & Andrews, R. (1996), Rule-extraction from trained neural networks: Different techniques for the determination of herbicides for the plant protection advisory system PRO_PLANT. Proceedings of the rule extraction from trained artificial neural networks workshop, Brighton, UK (pp. 133-139).

Weiss, S.M., & Kulikowski, C.A. (1990). Computer systems that learn. San Mateo,CA: Morgan Kauffman.

Wong, M.L.,& Leung, K.S. (2000). Data mining using grammar based genetic programming and applications. Kluwer Academic Publishers.

الفصل السابع

عدة طرق لاختيار المتغيرات بواسطة الخوارزميات الوراثية

ملخص

يظهر هذا الفصل عدة طرق لتحديد كيف يمكن للمجموعة الجزيئية الأكثر صلةً من المتغيرات أن تنفذ مهمة تصنيف. سيسمح هذا بتحسين فعالية نموذج التصنيف. تُطبق تقنية خاصة من الحوسبة التطورية - الخوارزميات الوراثية - التي تهدف إلى الحصول على طريقة عامة لاختيار المتغيرات، حيث سيعتمد فقط تابع الملاءمة على المسألة المعينة. يُطبق الحل المقترح، ويُختبر على حالة عملية في مجال الكيمياء التحليلية لتصنيف مشروبات التفاح.

مقدمة

إن الغرض الرئيس لأي طريقة تصنيف هو تعيّين صف أو صنف لجسم مُعطى، يُعرّف أو يُحدد ببعض الخواص أو المتغيرات. مع ذلك، لا تعطي كل تلك الخواص نفس نوعية وجودة المعلومات عندما يُنفذ التصنيف. أحياناً، يمكن أن تسبب المعلومات الكثيرة جداً (في هذا الفصل سيتضمن هذا المصطلح كلا المعلومات المفيدة والفائضة) مشاكل عند تعيين جسم ما إلى هذا الصف أو ذاك، مسبباً بالتالي تردي أداء التصنيف.

تشمل مسألة اختيار المتغيرات على اختيار مجموعة متغيرات جزئية من مجموعة عامة لها يمكن أن تنفذ التصنيف الأجود. بعض الفوائد المكتسبة بعد عملية اختيار ما هي التالية:

- تخفيض التكلفة لاكتساب البيانات: إذا طُلبت بيانات أقل من أجل تصنيف العينات، سيكون الزمن اللازم للحصول عليها أقصر.
- تحسين الكفاءة: أحياناً، قد تؤدي المعلومات الكثيرة جداً إلى تدهور قدرة التعميم لطريقة التصنيف.

- الكفاءة المتزايدة للنظام المُصنِّف: إن المعلومات الأقل تتطلب أيضاً زمناً أقل لمعالجتها.
- الفهم المُحسّن لنموذج التصنيف: تلك النماذج التي تستخدم معلومات أقل لتنفيذ نفس المهمة ستُفهم تماماً أكثر. كلما كانت معلومات المُصنِّف أبسط، كلما سَهُلَت عملية استخلاص المعرفة وصلاحيتها.

اختيار المتغيرات

أي عملية عامة لاختيار المتغيرات يمكن أن تُصاغ بواسطة التعريفات التالية:
إذا كانت A مجموعة من n جسم: $A = \{X_i, i = 1, ..., n\}$، وكل جسم X_i موصوف بمجموعة V من المتغيرات بحجم d، بحيث يكون كل متغير إما كميّاً أو نوعيّاً:

$$V = \{V_j, j = 1, ..., d\}$$

وإذا كانت C هي المجموعة العامة للصفوف التي سيتم منها التمييز، وC_k هي الصف الذي سينتمي إليه الجسم X_i، عندئذٍ يمكن أن يوصف أي جسم X_i بشكل تام بالمجموعة التالية:

$$X_i = \{V_{ij}, C_k\}, j = 1, ..., d$$

يجب أن يكون الهدف الرئيس لأي إجراء اختيار متغيرات هو الحصول على المجموعة الجزئية الأصغرية للمتغيرات S (SCV)، التي ما تزال تنفذ مهمة تصنيف مستوفية للشروط المطلوبة. تقليدياً، يتم الاقتراب من هذه المسألة بواسطة عدة تقنيات كلاسيكية متضمنةً المكونات الأساسية (Gnanadesikan, 1997)، تحليل العنقدة (Jain, Murty, & Flynn, 1999)، التوابع الكامنة (Tomas & Andrade, 1999; Forina, Armanino, Learde, Drava, 1991) طرق الاحتمالية العظمى مثل SIMCA (النمذجة المستقلة الناعمة لتناظر الصف) (Wold, Johansson، Jellum Bjornson, & Nesbakken, 1997) وهلم جراً...

الحوسبة التطورية

الحوسبة التطورية (EC) مركبة من مجموعة من التقنيات المُهمة من العالم البيولوجي. بينما هي تحاكي السلوك التطوري لأنواع الكائنات الحية، تعمل بتطور مجموعة من الحلول الممكنة لمسألة مُعطاة حتى الوصول إلى الحل الأمثل.

وبشكل منهجي أكثر، يتضمن مصطلح EC دراسة الأساس وتطبيق بعض التقنيات التجريبية التي تعتمد على أساسيات التطور الطبيعي (Tomassini, 1995)، يمكن أن تُصنّف هذه المجموعة من التقنيات التجريبية إلى أربعة أصناف رئيسية متضمنة في المعادلة التطورية الموضحة في (الشكل 1).

الشكل (1) المعادلة التطورية

حوسبة تطويرية	=	خوارزميات وراثية	+	استراتيجيات تطورية	+	برمجة وراثية	+	برمجة تطورية

الأساسيات البيولوجية

كما ذكر أعلاه، فإن الخوارزميات الوراثية بالأصل تحاول محاكاة بعض العمليات التي تحدث في التطور الطبيعي. وبعض هذه العمليات الجديرة بالملاحظة أكثر هي بقاء السلاسل الفردية الأفضل والاصطفاء الطبيعي وكلاهما قُدِّما للنشر من قبل العالم Charles Darwin (Darwin, 1859). على الرغم من أن تفاصيل العملية التطورية الطبيعية ما تزال مجهولة وغير مفهومة بشكل عام حتى الآن، فإن الأحداث التي تأخذها EC كأساس لها تمتلك أدلة تجريبية قوية:

- التطور هو العملية التي تتعامل مع الصبغيات بدلاً من الكائنات الحية، قد تعتبر الصبغيات كأدوات عضوية تُشفر الحياة أو – من وجهة نظر حسابية – حل لمسألة ما.
- الاصطفاء الطبيعي هو الآلية التي تربط الصبغيات بفعالية أخذاً بالاعتبار الكيان الذي تمثله. وهذا يزود السلاسل الفردية المتكيفة الأفضل للبيئة بعدد أعلى من فرص التكاثر.
- تحدث العمليات التطورية خلال المرحلة التكاثرية.

هناك آليات عديدة تتعلق بالتكاثر، وأكثر هذه الآليات شيوعاً هي التصالب أو إعادة الدمج، الذي يدمج صبغيات الآباء بغية إنتاج النسل، والطفرة التي تحث عشوائياً المادة الوراثية للنسل لتكون مختلفة عن مثيلتها للآباء.

العملية الأساسية للخوارزمية التطورية

أي خوارزمية تطورية هي عملية تكرارية وعشوائية، تعمل مع مجموعة من الحلول الممكنة لمسألة ما تعرف كمجتمع وراثي (Goldberg, 1989). بداية، يُولّد هذا المجتمع عشوائياً، ويتم تضمين الحلول باستمرار بعد المراحل المتتالية من التصالبات والطفرات، تمتلك كل سلسلة فردية في المجتمع قيمة ما، تكون مرافقة لضبطها أو ملاءمتها بموجب كفايتها لحل المسألة. هذه القيمة – التي يجب أن يُحصل عليها لكل سلسلة فردية أو لكل حل ممكن – هي المعلومات الكميّة التي

تستخدمها الخوارزمية التطورية لتوجيه البحث. وتستمر العملية حتى الوصول إلى معيار توقف محدد مسبقاً، قد يكون تحقيق خطأ عتبي معين للحل، أو عدد محدد من التوليدات. هذه العملية موصوفة في (الشكل 2).

الشكل (2) *الشيفرة الكاذبة لخوارزمية تطورية أساسية.*

```
توليد المجتمع الابتدائي P(0)
t → 0
طالما أنه لم يتحقق معيار التوقف (حلقة While)
    تقييم P(t)
    اختيار (P(t)) ← P'(t)
    تكاثر (P'(t)) ← P"(t)
    تعويض من أجل (P(t), P"(t) ← P(t+1)
    t ← t + 1
نهاية الحلقة (While)
إعادة الحل الأفضل عند P(t)
```

تقنيات الحوسبة التطورية لاختيار المتغيرات

من بين الاستراتيجيات التي يمكن أن تُتبع لاختيار مجموعة جزئية من المتغيرات، تبرز تقنية EC المعروفة بالخوارزمية الوراثية (GA). سيتم التعليق هنا فقط على تلك السمات المتعلقة بترميز المسألة. كما يلاحظ من الشيفرة الكاذبة الموضحة في (الشكل 2)، من الضروري تعيين آلية لتحديد إلى أي مدى تنتج سلسلة فردية من المجتمع الوراثي حلاً جيداً. هذا يعني، بأنه يجب أن يُحدد تابع تقييم، على الرغم من أن التابع المعين للاستخدام سيعتمد على المسألة المعينة التي في المتناول.

في القسم الثاني، سوف تُطرق مسألة اختيار المتغيرات في مجال القياس الطيفي للأشعة تحت الحمراء بواسطة مثال معين، يجب أن يُوصف فيه تابع التقييم من أجل كل طريقة اختيار متغيرات مختلفة.

البحث المُشذب

في هذه الطريقة الأولى، تُستخدم GA لتحديد أي المتغيرات يساهم أكثر في تحديد الصف لكل جسم وكم هو عددها. تقلل GA بثبات كمية المتغيرات، التي تصف الأجسام حتى الحصول على المجموعة الجزئية المثالية، التي تسمح بتصنيف عام مستوفٍ للشروط المطلوبة.

يتم في هذه الطريقة وصف كل سلسلة فردية في المجتمع الوراثي بواسطة n مورثة، تمثل كل واحدة منها متغيراً واحداً. يمكن أن يكون الترميز الثنائي لكل مورثة إما 0 أو 1، مشيراً إلى ما إذا كانت المورثة نشيطة أم لا، وبالتالي إن كان يجب أن يُؤخذ المتغير بالحسبان من أجل التصنيف.

يجب على تابع التقييم أن يوجه عملية التشذيب بغية الحصول على سلاسل فردية بعدد قليل من المتغيرات. ولإنجاز ذلك، يجب أن يساعد التابع هذه السلاسل الفردية بحيث – إلى جانب التصنيف بدقة – يقوم باستخدام متغيرات أقل. يوجد خيار موصوف بالمعادلة 1. وهو يُحدد الملاءمة تبعاً لبارامترين هما: عدد المتغيرات المستخدمة من قبل السلاسل الفردية لتصنيف العينات، وجودة التصنيف المُنجز باستخدامها. السلاسل الفردية الأفضل هي تلك ذات الملاءمة الأقرب إلى 0، لأن تابع التقييم سيوجه بحث الـــ GA على طول اتجاهين متوازيين. يجب على الحلول أن تجعل الفرق أصغرياً بين عدد أخطاء التصنيف المكتسب باستخدام كافة المتغيرات وعدد الأخطاء عندما تُستخدم فقط المتغيرات المختارة بـــ GA. طالما أنه تُفضل الحلول التي تستخدم متغيرات اقل، فيمكن التصريح بأنه كلما كانت هاتان السمتان للتابع أقل، كلما كان الحل المُصنّف بالسلسلة الفردية أفضل.

المعادلة 1.

البحث المُشذّب. التقييم العام

$$fit_i = f(clas_i) + f(sel.Vars.)$$

حيث أن fit – الملاءمة. Clas – تصنيف، Sel.Vars – متغيرات مختارة.

تعتمد المصفوفات التي سوف تُستخدم عند تقييم جودة التصنيف على المسألة التي في المتناول، وضمنها النسبة المئوية للأجسام التي صُنفت بشكل صحيح (باستخدام المتغيرات المختارة فقط)، وعدد الأخطاء، ... وهلم جراً. هناك خياران عندما تؤخذ بالاعتبار المجموعة الجزئية من المتغيرات التي تم اختيارها من أجل التصنيف وهما: استخدام أصلية هذه المجموعة، ونسبتها المئوية نسبةً لكامل المتغيرات الموجودة.

إذا كان التابع الذي يقيّم جودة التصنيف يمكن أن يُحدّد بقيمة عليا (على سبيل المثال، العدد الكلي للأخطاء)، فمن الممكن تثقيل أهمية كلٍّ من أطراف المعادلة. وبالتالي، سيكون تابع الملاءمة مشابهاً للمعادلة 2. حيث تمثل α عامل التثقيل.

المعادلة 2.

البحث المُشذّب. التقييم العام بالتثقيل.

$$fit_{indi} = \alpha.f(Clas_i) + (1 - \alpha) . f(sel.vars), \alpha \in [0 .. 1]$$

حيث أن fit_{ind} – ملاءمة السلسلة الفردية. $Clas_i$ – التصنيف. sel.vars – متغيرات مختارة.

البحث الثابت

في الطريقة الثانية، تُحدد GA فقط ما هي المتغيرات البارزة من أجل التصنيف، بينما يحدد ترميز السلاسل الفردية مسبقاً كم عدد هذه المتغيرات. بغية الحصول على هذه المعرفة المسبقة، يمكن أن تُستخدم طريقة دوران العالم Procrustes لتحديد العدد الأصغر للمتغيرات اللازمة لتصنيف مرضٍ (Krzanowski, 2001). يحدد هذا العدد طول السلسلة الفردية الوراثية، التي يمكن أن يُنجز فيها تشكيل GA. طالما أن النمط الوراثي يحدد عدد المتغيرات المستخدمة للتصنيف، فإن GA ستركز فقط على تمييزها والتعرف عليها.

بشكل متميز تماماً عن الطريقة السابقة، تستخدم هذه الطريقة ترميزاً حقيقياً لصبغي السلاسل الفردية الوراثية. هنا، تمثل كل مورثة دليل المتغير الذي يُعتبر ممثلاً للتصنيف.

باستخدام هذا البديل، سيعتمد تابع التقييم فقط على الحد الأول الذي هو تابع لجودة التصنيف، لأن أصلية مجموعة المتغيرات الجزئية تكون معلومة مسبقاً.

بحث متعدد الشكلية

في بعض المناسبات لا يُقدم الحل لمسألة ما بواسطة قيمة مثلى محلية وحيدة، وإنما من أجل عدة قيم. وفي بعض الحالات الأخرى، يكون من المفضل تزويد حلول متعددة، بحيث قد يختار الخبير المسؤول عن التطبيق أو لا يختار الحل الأفضل (رياضياً أما القيمة المطلقة العظمى أو الصغرى)، وإنما يختار الحل الذي يعطي أقل تعقيد عملياً بالنتائج المكافئة. في حالات كهذه، تُعرّف المسائل كمسائل متعددة الشكلية.

تمثل أي مسألة متعددة الشكلية تحديين لأداء GA أساسية (Harik, 1995). يكمن التحدي الأول في أن هذا النوع من المسألة يمتلك عادةً عدداً عالياً من المتغيرات، الذي يسبب تردي أداء GA الأساسية. أما التحدي الثاني، فهو أن أي GA تقليدية تتجه إلى تركيز البحث على طول المنطقة حيث يوجد الحل الأكثر توقعاً وبالتالي إزالة المناطق الأقل توقعاً، بينما تتقدم التوليدات. بعض

التعديلات التي تعنون هذه القيود هي GA غير مرتبة (Whitley, 1997)، التي تظهر لتكون أقوى عند العمل بعدد عالٍ من المتغيرات والتقنيات متعددة الشكلية كاحتشاد (DeJong, 1975)، والتي تبحث عن مخطَّطاتٍ جديدة لتوليد سلاسل فردية، أو من أجل استبدالها بغية تفادي تجانس المجتمع. التعديل الآخر هو مشاركة الملاءمة (Sareni, 1998)، التي تحاول الحفاظ على تنوع المجتمع خلال استكشاف ذرى متعددة.

تكمن طريقتنا الخاصة لاستخدام GA لحل مسائل متعددة الشكلية في استخدام GA هجينة ذات مجتمعين (HTP-GA). بشكل مختصر، يضيف هذا الحل مجتمعاً جديداً – يسمى بالبركة الوراثية – إلى GA التقليدية. تمثل كل سلسلة فردية في هذا المجتمع الجديد مجالاً جزئياً من فضاء البحث (الفضاء العام مُشكّل بكافة الحلول الممكنة، وفي هذه الحالة، بكافة توليفات المتغيرات). تمتلك هذه السلاسل الفردية خاصية مفادها أن مورثاتها يمكن أن تتغير فقط ضمن مجال محدد من القيم. وهنا، ضمن مجموعة من المتغيرات (على سبيل المثال، مجالات المتغيرات [4 ... 1]، [8 ... 5] ... الخ). وهذا يجبر توزيع السلاسل الفردية الوراثية على طول كامل فضاء البحث، الأمر الذي يحمي تنوع المجتمع بينما تمر أجيال عبره.

كنتيجة للتوزيع التجانسي للسلاسل الفردية على طول فضاء البحث، يمكن أن تجد GA – وتبقي داخل المجتمع الوراثي – حلولاً صالحة مبتعدة عن بعضها البعض في فضاء البحث، بينما عند استخدام GA تقليدية، فإنها تتجه نحو تركيز البحث ضمن منطقة مقيدة، في حين تتقدم الأجيال. يمكن أن تفصّل طريقة HTP-GA في القسم الفرعي التالي.

الخوارزمية الوراثية الهجينة ذات المجتمعين

- تعتمد GA المقترحة على GA تقليدية المعززة بمجتمع جديد (البركة الوراثية) بغية إجبار بحث متجانس على طول كامل فضاء الحلول.

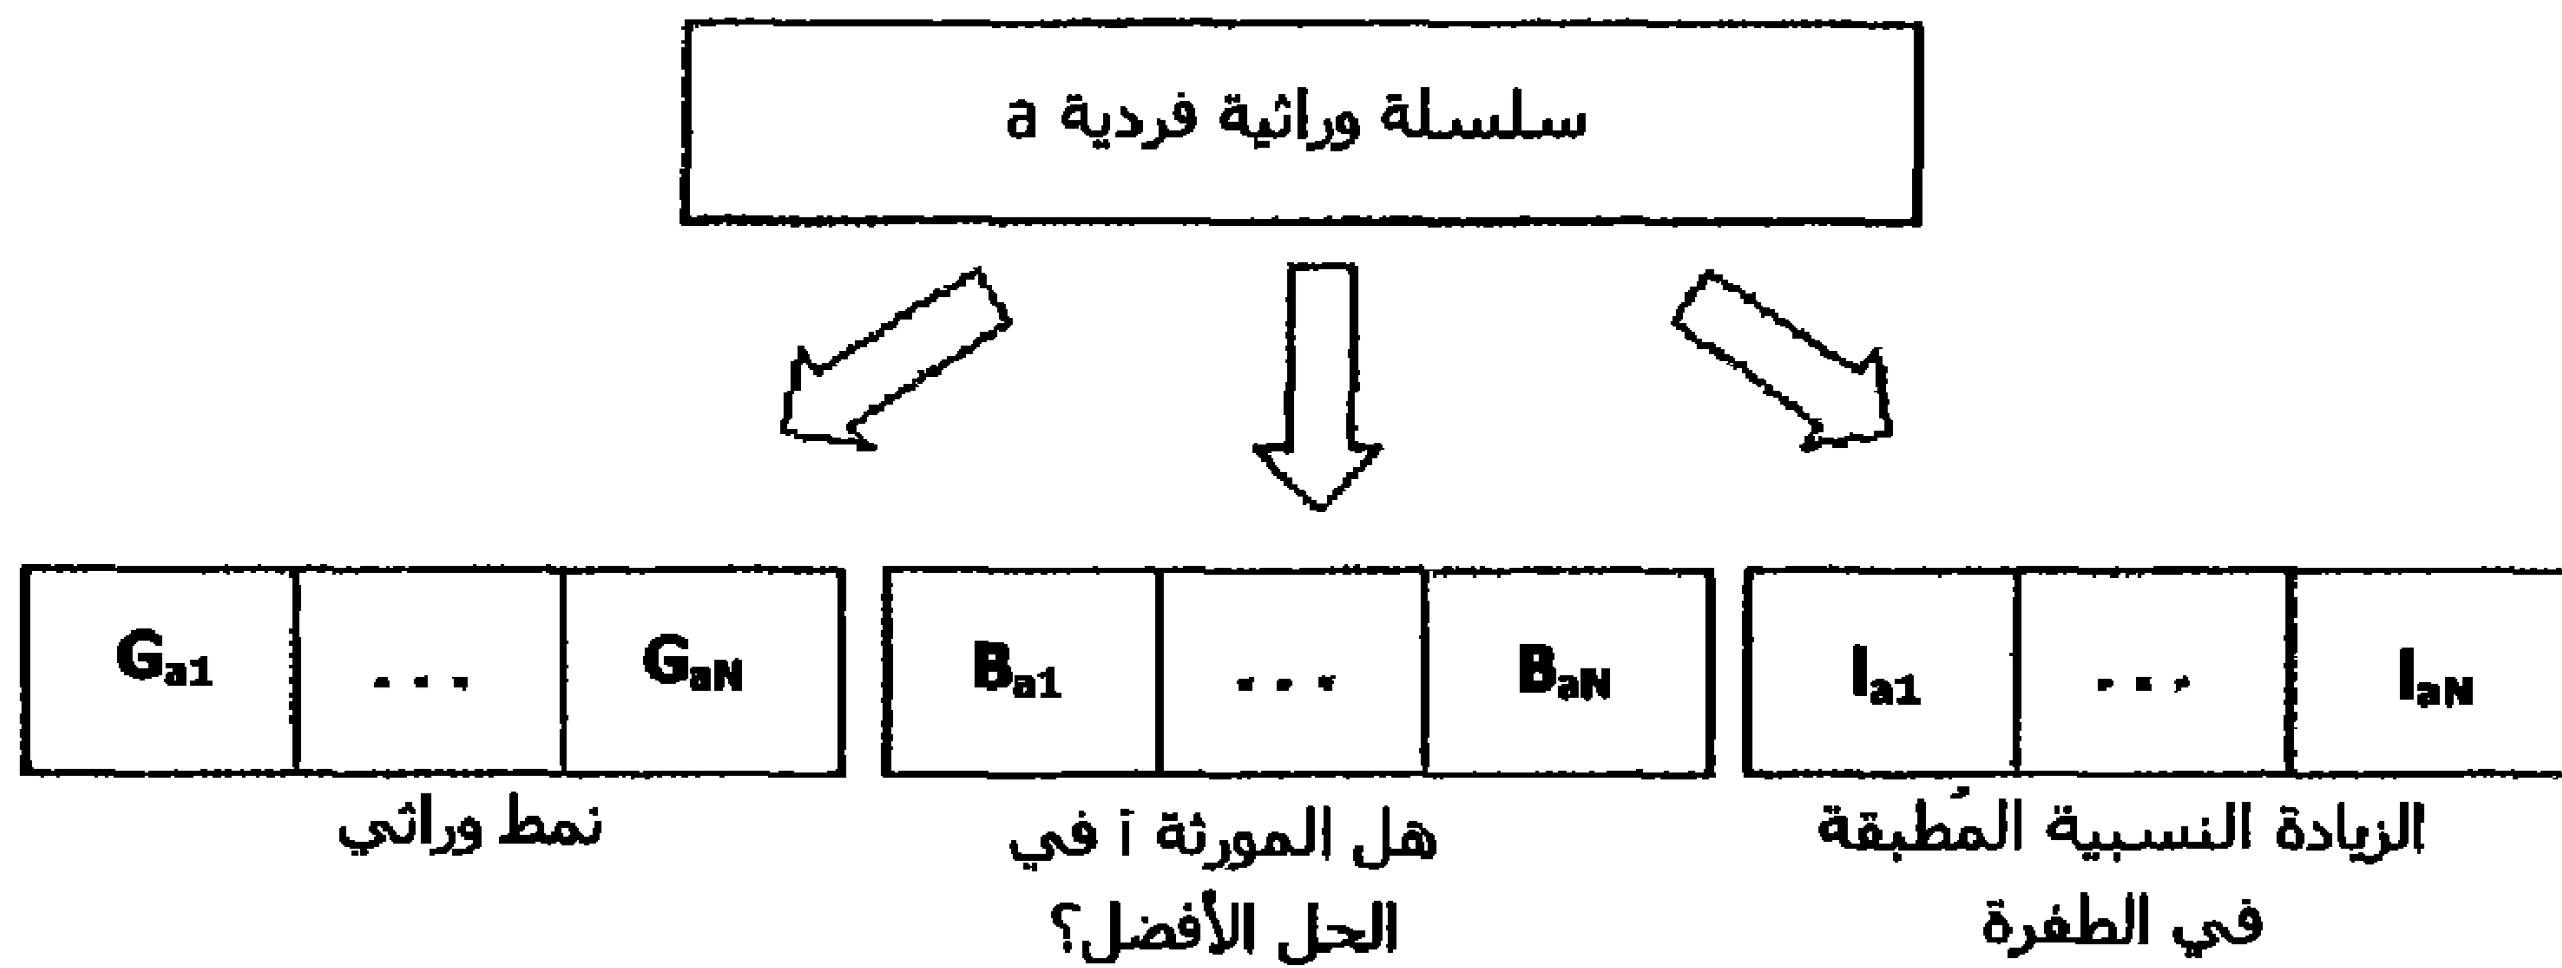
بالإضافة إلى البرمجة الوراثية، يُستخدم أيضاً مجتمع آخر (المجتمع الثانوي). يتطور المجتمع الثانوي الموجّه بواسطة GA كلاسيكية بالاتصال مع السلاسل الفردية للبركة الوراثية. يكون المجتمع الثانوي مسؤولاً عن إعطاء الحلول، بينما ستعمل البركة الوراثية كمحرك البحث عن تلك الحلول بإبقاء فضاء البحث المُستكشف متجانساً. بناءً على تعقيد المسألة، سيكون على المستخدم اختيار عدد مختلف من المناطق الفرعية التي يريدها في فضاء البحث (أو عدد السلاسل الفردية في البركة الوراثية أو طول المناطق الفرعية). ولاحظ بأن أي GA تقليدية، تعتبر فقط منطقة فرعية واحدة (كامل فضاء البحث)، التي تصبح مخفضة تدريجياً.

وصف المجتمعات: البركة الوراثية

بما أن سلاسلها الفردية تمثل مناطق جزئية ضمن فضاء البحث العام، فإن لديها نفس البنية (أو السلسلة الوراثية) بخلاف GA التقليدية. ويكمن الاختلاف في قيم المورثات التي تملكها. بينما تكون في GA تقليدية أي قيمة صالحة ضمن فضاء البحث، فإن مجال القيم مقيّد من أجل مورثات السلاسل الفردية للبركة الوراثية. يُقسم المجال الكلي للقيم (العدد الكلي للمتغيرات، على سبيل المثال) إلى مجالات عدة كعدد السلاسل الفردية في البركة الوراثية. وفقاً لذلك، يكون لكل سلسلة فردية في المجتمع مجال جزئي خاص بها من القيم المعينة، ثم يمكن أن تأخذ كل مورثة لسلاسل البركة الوراثية الفردية فقط القيم المحتواة في مجالها المرافق.

يجب على كل سلسلة فردية في البركة الوراثية أن تعرف ما هي جيناتها المتضمنة في الحل الأفضل للمجتمع الثانوي (ويجب أن يُعدّل ذلك من أجل كل توليد). تُعطى هذه المعرفة على شكل قيم منطقية تتفادى تعديل مورثات الحل الأفضل. لدى كل مورثة لكل سلسلة بركة وراثية فردية قيمة مرافقة I تدل على الزيادة النسبية التي ستُطبق على المورثة أثناء حدوث طفرة. ومن الواضح أن هذه الزيادة لا تستطيع أن تجعل قيمة المورثة تتجاوز المجال، الذي يُسمح لهذه المورثة أن تتغير ضمنه. يظهر (الشكل 3) بنية سلاسل البركة الوراثية الفردية. بما أن هذه السلاسل الفردية لا تمثل حلولاً عامة للمسألة الواجب حلها، فإن تقييم ملاءمتها ليس إلزامياً.

الشكل (3) *صيغي السلاسل الفردية في البركة الوراثية*



وصف المجتمعات: المجتمع الثانوي

على نقيض البركة الوراثية، يمكن لمورثات السلاسل الفردية في المجتمع الثانوي أن تأخذ أية قيمة في كافة أنحاء الفضاء الكامل للحلول الممكنة. بهذا الأسلوب، يقدم المجتمع الثانوي حلولاً عامة للمسألة، الأمر الذي لا يمكن أن تقوم به أيٌّ من السلاسل الفردية في البركة الوراثية، لأن مورثاتها مقيدة إلى مجالات جزئية.

سوف ينفذ تطور السلاسل الفردية في هذا المجتمع بواسطة قواعد GA التقليدية، ولكن مع استخدام تصالب مختلف طالما أن الأبوين لن ينتميا إلى نفس المجتمع. لذا، تم دمج البركة الوراثية والمجتمع الثانوي عوضاً من ذلك.

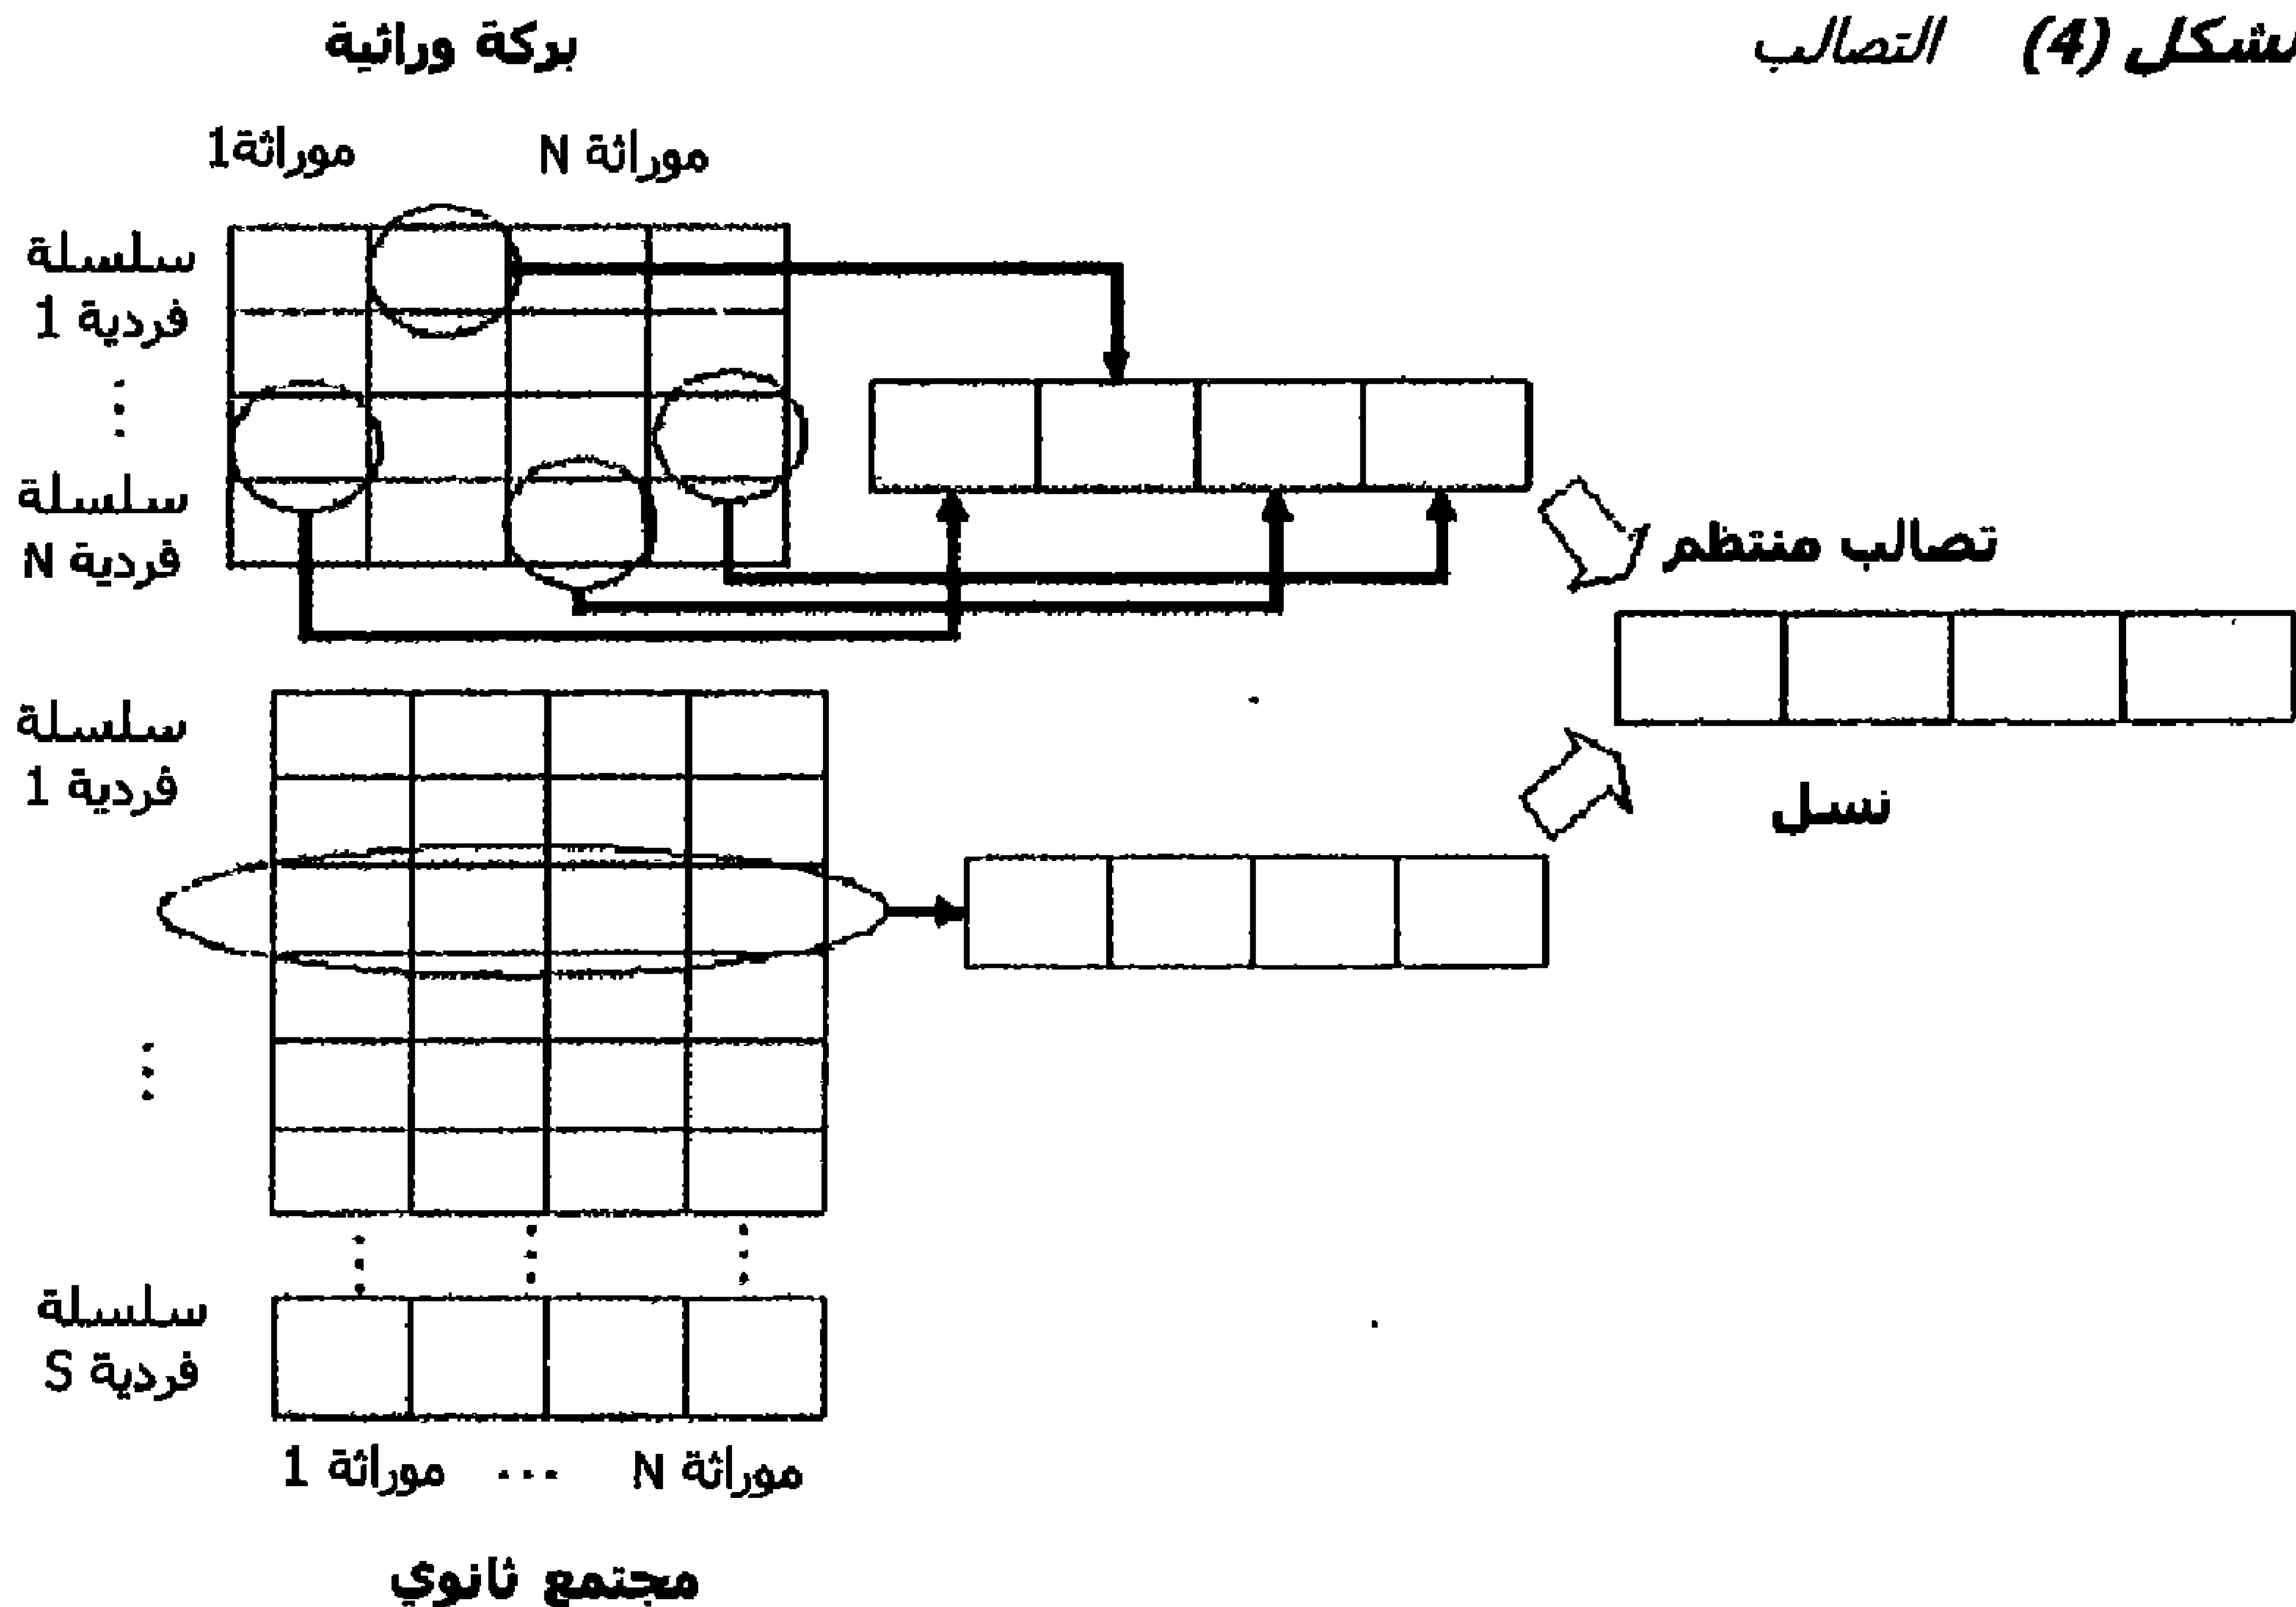
المعاملات الوراثية في HTP-GA

كما هو الحال في GA الكلاسيكية، يُنفذ تطوير الحلول في HTP-GA بتطبيق معاملات الطفرة والتصالب. وتكون الاختلافات الوحيدة في التصالب (كما تم شرحه مسبقاً)، وتكون أقل في معامل الطفرة.

التصالب

يدمج التصالب سلسلة فردية من المجتمع الثانوي مع أخرى ممثلة للبركة الوراثية. نقترح أن يتم اختيار الأولى عشوائياً. وبالتالي، لا حاجة لأن يكون المجتمع الثانوي مرتباً بملاءمة السلاسل الفردية. وكنتيجةً لذلك، سيحدث تحسين في زمن التنفيذ. ويُبنى أي ممثل بركة وراثية بطريقة، بحيث تؤخذ بالاعتبار كافة مورثات البركة الوراثية. تُختار كل مورثة للمثل عشوائياً وبشكل مستقل من بين كافة السلاسل الفردية انظر (الشكل 4) لا يعد الممثل – على خلاف السلاسل الفردية للبركة الوراثية – حلاً جزئياً وإنما عاماً.

الشكل (4) التصالب



يُنفذ بعد ذلك تصالب منتظم، ويُنتج تطبيقه سلسلة فردية واحدة فقط (لأن سلسلة فردية واحدة فقط أُستخلصت من المجتمع الثانوي)، أُختيرت مورثاتها بشكل عشوائي من أبويها. تم إجراء عملية الإدخال إلى المجتمع الثانوي بواسطة خوارزمية استبدال غير هدّامة، بحيث يُنفذ الإدخال لوحده، عندما تكون ملاءمة النسل أعلى من ملاءمة الأب من المجتمع الثانوي.

إذا أدى التصالب إلى حل أفضل من تلك الحلول المخزنة، يجب عندها أن تُبدل المورثات الأصلية المأخوذة من البركة الوراثية في التوليد التالي. وبالتالي، يتغير تحكمها أو مورثاتها المنطقية (B_{ij} في الشكل 3) وفقاً لذلك.

الطفرة

يتضمن تطبيق معامل الطفرة اختياراً عشوائياً لإحدى السلاسل الفردية من البركة الوراثية بغية تحوّل إحدى مورثاتها. تنتج القيمة الجديدة من زيادة (نقصان) القيمة القديمة بالزيادة المعينة على "المورثة التزايدية" المرافقة لها (المرمزة بـــ I على الشكل 3). انظر الشيفرة الكاذبة في (الشكل 5).

يجب ألا تحوّل المورثات المُعتبرة كأفضل حلول للمجتمع الثانوي. كما ذكر أعلاه، إذا شكلت الزيادة تجاوزاً لقيمة المورثة للحد العلوي للمجال الجزئي التي يُسمح للمورثة أن تتغير ضمنه (LIM-SUP-IND)، فإنها تبدّل إلى القيمة الأدنى للمجال الفرعي (LIM-INF-IND). علاوة على ذلك، فإن القيمة التزايدية التي قد تُطبق على طفرات لاحقة للمورثة تُخفض أيضاً (مُتحكم بها بواسطة قيم دلتا). ويحاول هذا أن ينفذ بحثاً أكثر شمولية عبر كافة القيم التي قد تأخذها مورثة مُعطاة، بينما تُحسّن التوليدات. تُشغّل قيمة الدلتا وفقاً للمعادلة (3). وبالتالي، ستُطبق فقط على السلاسل الفردية المنتمية للبركة الوراثية.

الشكل (5) *الشيفرة الكاذبة للطفرة*

```
IF (not Bi)
  Gi = Gi + Ii
  IF (Gi > LIM-SUP-GEN)
  Gi = LIM-INF-GEN
  Ii = Ii - Delta
ENDIF
ENDIF
```

المعادلة 3.

بدء الدلتا، IND-Poll = عدد السلاسل الفردية للبركة الوراثية

$$\frac{(LIM-SUP-IND)-(LIM-INF-IND)}{IND-POOL}$$

تطبيقات عملية: اختيار المتغيرات الطيفية للأشعة تحت حمراء (IR) لتصنيف مشروبات التفاح

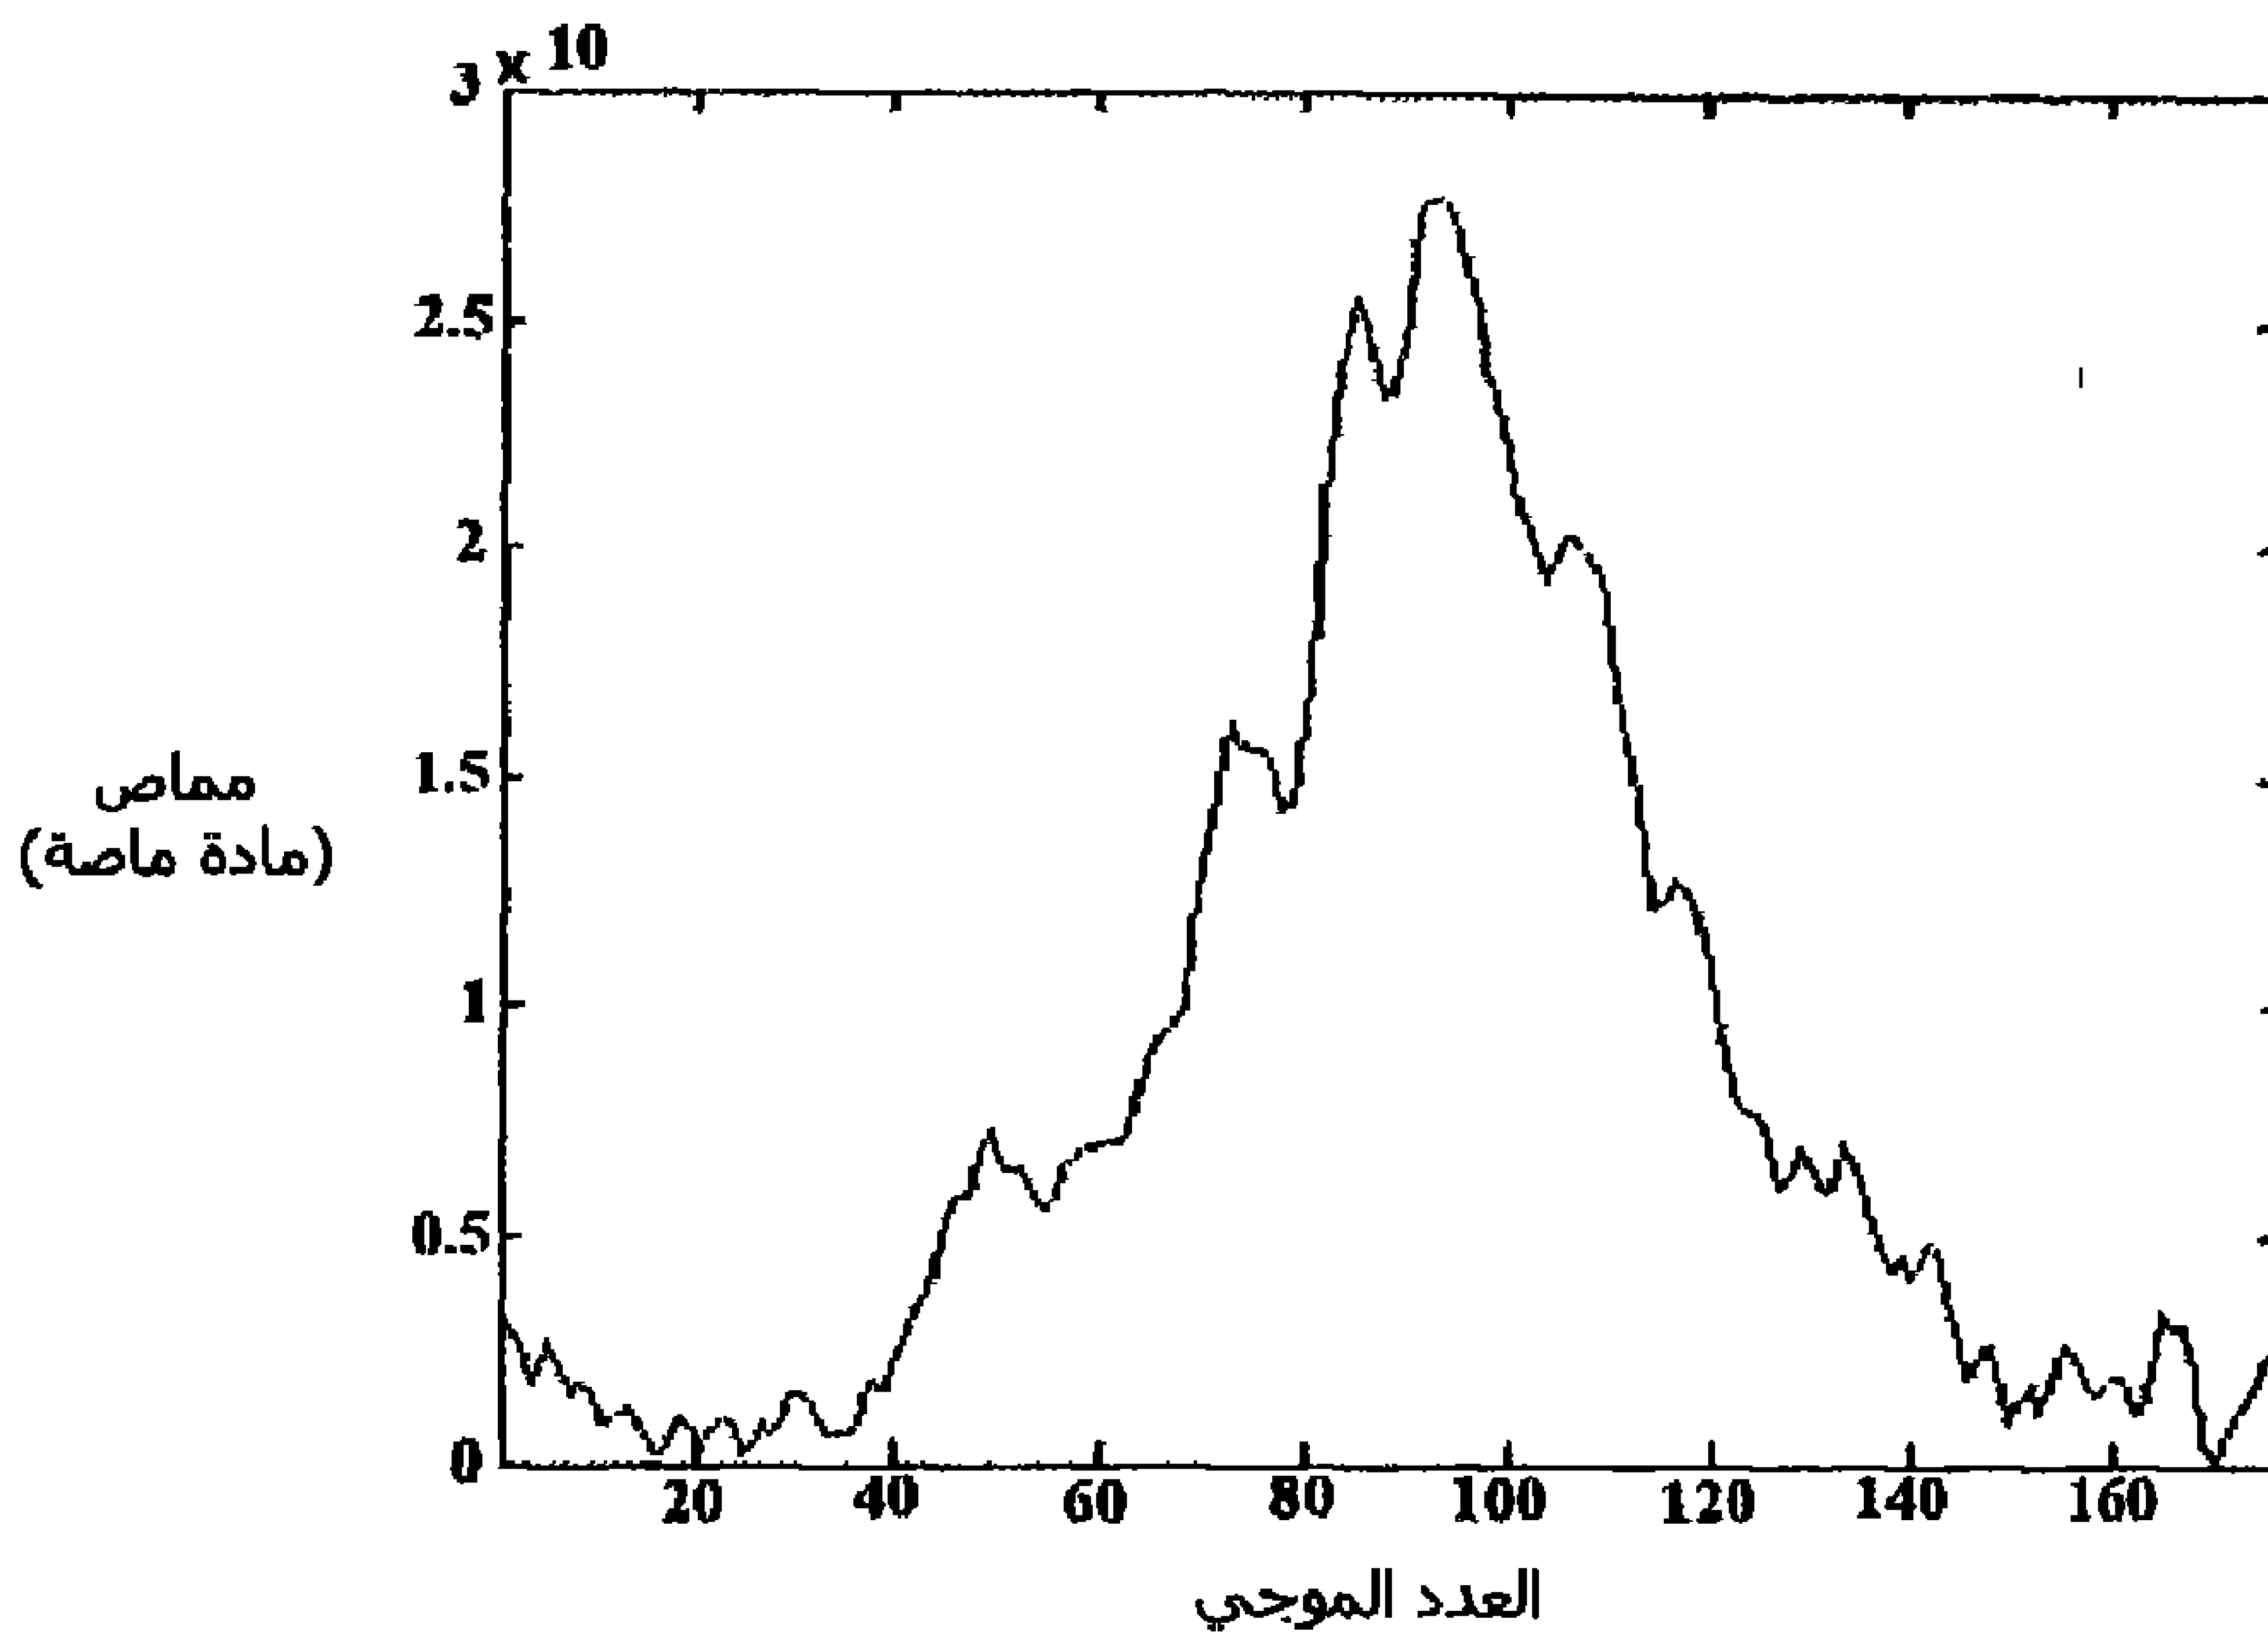
بينما زاد استهلاك عصائر الفاكهة بشكل هائل خلال السنوات العشر الماضية، فإن تقنيات التحايل المرافقة والهادفة لتحقيق أرباح أعلى (على سبيل المثال، بلُصاقات غير مناسبة أو بإضافة سكر) قد ازدادت أيضاً. في محاولة لإيقاف هذا الاتجاه، حددت توجيهات الاتحاد الأوروبي الجديد بيانات غنية بالمعلومات المفيدة الإلزامية كي تُطبع على الحاويات الفردية مثل أصل الفاكهة وكمية العصير الصافي. إن إضافة السكر هي الطريقة الأكثر شيوعاً والبسيطة لغش العصير. وقد تكون الطرق الأخرى بإضافة مواد عديدة كالماء، المواد الملونة، العصير الأقل جودة، أو لب الفاكهة (Saavedra, García & Barbas; 2000).

هناك تقنيات مختلفة لكشف تلك المخالفات مثل HPLC (Yuan & Chen, 1999)، والفصل الكروماتوغرافي الغازي (بالابتزاز في طبقات مختلفة اللون) (Stöber, Martin, & Pepper, 1998)، أو الطرق النظائرية (Jamin, González, Remaud, Naulet, & Martin, 1997)، التي تصف أي عصير فاكهة من وجهة نظر نوعية وكمية. ومشكلتها الرئيسة هي أن جميع هذه الطرق تعتبر تقنيات تحليلية معقدة، التي تتطلب الكثير من الوقت والمال.

أما الطريقة الأخرى التي يمكن أن تُستخدم فهي مطياف الأشعة تحت الحمراء (IR)، الذي يمكن أن يقيس الطيف الكامل للعينة خلال بضعة ثواني. يعتمد المطياف على انعكاس الضوء التبايني و/أو امتصاص الأجسام. تستجيب أي عينة بشكل مختلف لأطوال موجية مختلفة. وتكون الاختلافات ناجمة عن التركيب الكيميائي وبنية الجزيئات المُحلّلة. لذا، يكون تمييز العينات بتراكيز مختلفة للعصير الطبيعي خطوة سابقة لكشف العصائر المغشوشة.

تكون كمية المعلومات المُستخلصة من أي عينة بواسطة IR ضخمة جداً. في التطبيق الحالي، يزود المجال الطيفي الصغير الذي تم قياسه (أطوال موجية من 1.250 سم$^{-1}$ إلى 900 سم$^{-1}$) 176 مادة ماصة (المتغيرات التي تقيس امتصاص الضوء). يظهر (الشكل 6) مثالاً نموذجياً لعصير التفاح. من المعقد جداً إثبات ما إذا كانت كل هذه البيانات تزود نفس الكمية من المعلومات لتفاضل العينة. وهكذا، فإن تطبيق طرق رياضية و/أو حسابية يستغرق الكثير من الزمن. ووفقاً لذلك، تصبح الخصائص الطيفية لعصائر الفواكه حالة مناسبة لاستخدام تقنيات اختيار المتغيرات، التي تعتزم تقليل الزمن اللازم للقياسات التجريبية من أجل تطبيق الطرق الرياضية، وأيضاً لاستخلاص الاستنتاجات الكيميائية فيما يتعلق بالأطوال الموجية تلك، التي تعطي كمية أعلى من المعلومات لخصائص العينة.

الشكل (6) *الطيف النموذجي لعصير التفاح.*



العينات

قبل اختيار المتغيرات، يكون تشكيل مجموعات بيانات لكلٍّ من تحسين وصلاحية النموذج إلزامياً. لذا، فقد حُضّرت مسبقاً عينات بكميات مختلفة من عصير التفاح الصافي في المختبر، ثم تم شراء وتحليل ثلاثة وعشرين مشروباً معتمداً على عصير التفاح تباع في إسبانيا (كانت كمية عصيرها المصرح به مطبوعة على لصاقاتها). وزعت العينات إلى مجموعتين: عينات حاوية على أقل من 20 % من العصير الصافي (الجدول 1)، وعينات بأكثر من 20 % من عصير التفاح الصافي (جدول 2). تم الحصول على طيف IR باستخدام مقياس الطيف Perkin Elmer 16PCFTIR المُجهز بلوح ATR من السلينوم التيوتياء (50 مسح، 4 سم$^{-1}$ تميز، تصحيح خط أساس بين 1.250 إلى 900 سم$^{-1}$، كاشف DTGS). وتمت رقمنة الطيف (1 بيان/2 سم$^{-1}$).

استُخدمت مجموعات بيانات مختلفة مستقلة لاستخلاص القواعد (تدريب ANN) وإثبات الصلاحية. استُخدمت العينات التجارية لتنفيذ اختبار إضافي لأداء النموذج. من الجدير بالذكر أنه إذا لم تتطابق القيمة المتوقعة مع تلك المُعطاة على لُصاقات المنتجات التجارية، فإن ذلك يكون إما بسبب أداء خاطئ للنموذج الحقيقي (تصنيف)، أو دمغ غير صحيح للمشروب التجاري.

الجدول (1) عدد من العينات بتراكيز منخفضة للعصير الصافي.

تراكيز منخفضة 2 % - 20 %			
تجاري	صلاحية	تدريب	تركيز
0	1	19	%2
0	1	17	%4
0	13	16	%6
0	6	22	%8
1	6	21	%10
1	6	20	%16
0	6	19	%20
2	**39**	**134**	**المجموع**

الجدول (2) عدد من العينات بتراكيز عالية للعصير الصافي

تراكيز عالية 20 % - 100 %			
تجاري	صلاحية	تدريب	تركيز
0	6	20	%20
2	18	19	%25
0	13	16	%50
0	1	14	%70
19	6	17	%100
21	**41**	**86**	**المجموع**

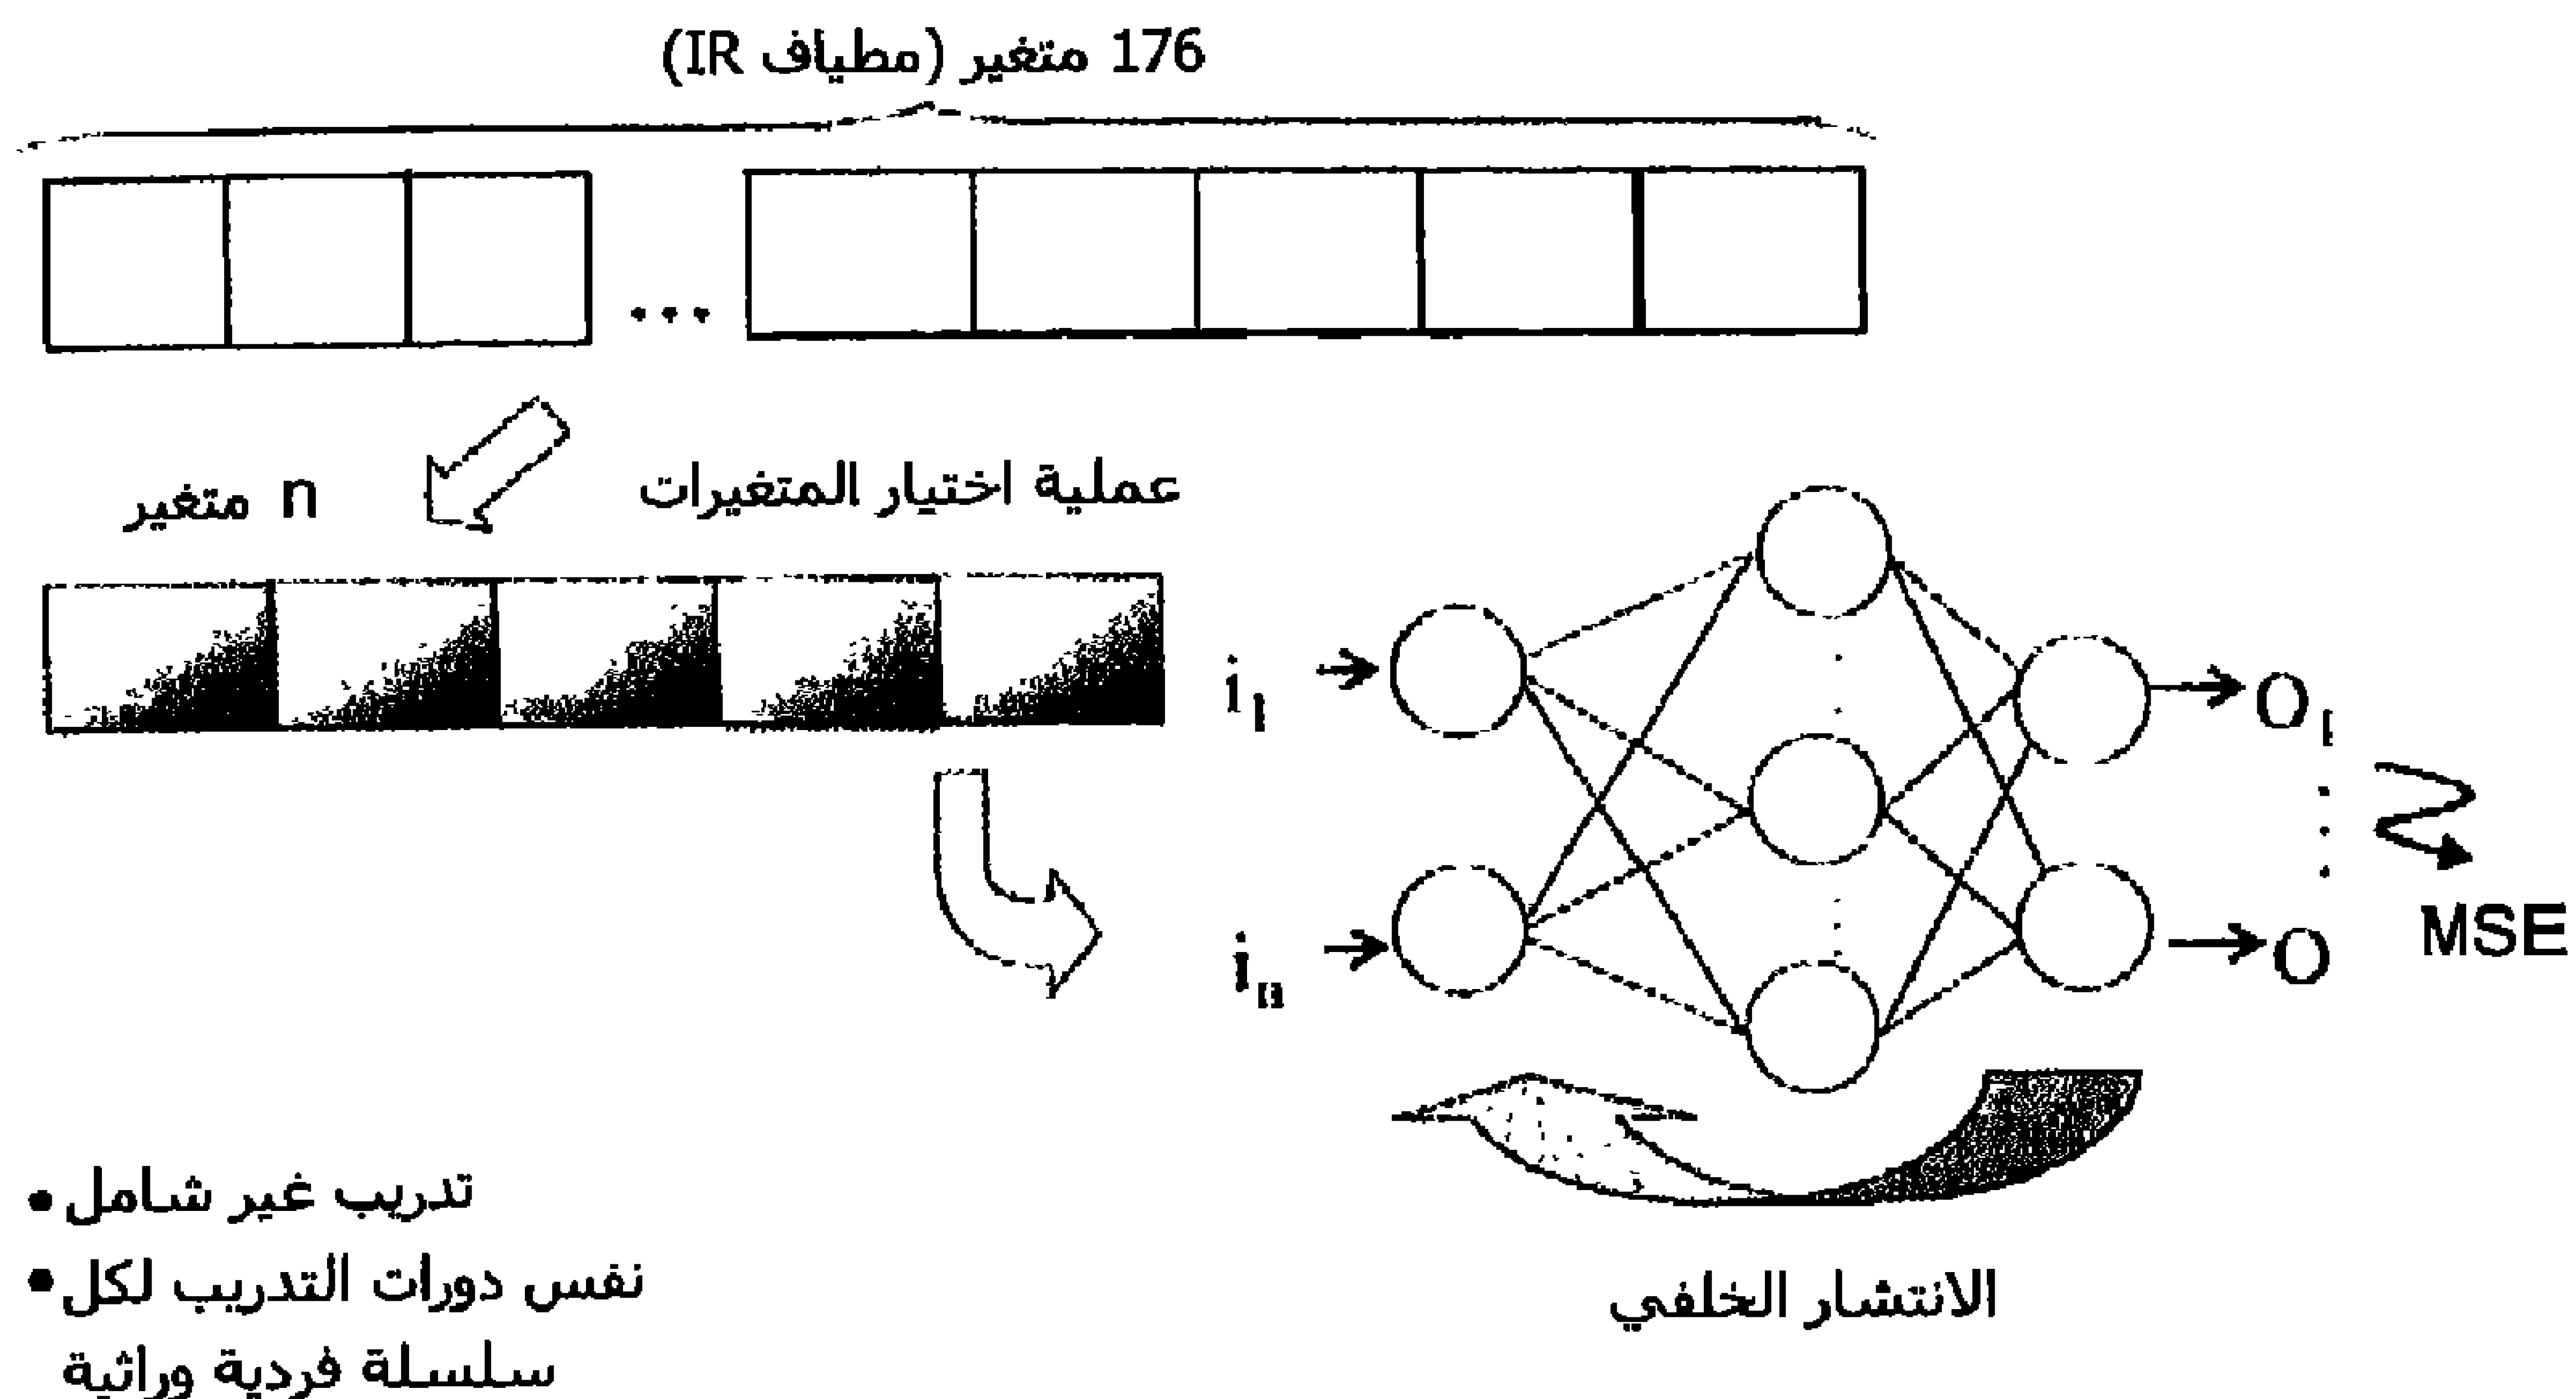
تقييم الحل

أظهرت الدراسات السابقة (Gestal et at., 2004; Gestat et at. 2005)، بأن ANN تصنف مشروبات عصائر التفاح وفقاً لتركيز العصير الطبيعي المحتواة فيها، وأن ANN تمتلك أفضليات على الطرق الإحصائية الكلاسيكية لتحسين نموذجي أسرع وتطبيق سهل للمنهجية في مختبرات R & D.

تم هنا الأخذ بالاعتبار GA لتوجيه البحث عن العدد الأصغر للمتغيرات بتقييم إمكانيات التوقع لنماذج ANN مختلفة مطورة باستخدام مجموعات مختلفة من متغيرات IR. في الأقسام السابقة، تم وصف ثلاثة بدائل لاختيار المتغيرات (وهي: البحث المُشذب، البحث الثابت، والبحث HTRGA متعدد الشكلية)، وسوف تُختبر جميعها هنا لاحقاً (انظر (الشكل 7) لتمثيل كامل العملية).

المسألة التي ستُطرح هي اكتشاف مجموعة صغيرة من متغيرات IR التي – عندما تُدمج مع نموذجٍ ANN – تكون قادرة على تصنيف مشروبات معتمدة على عصير التفاح بشكل ملائم (تبعاً لكمية عصير التفاح الصافي التي تحتويها هذه المشروبات).

الشكل (7) مخطط تقييم السلاسل الفردية الوراثية



حالما تُقترح مجموعة جزئية من متغيرات IR، يتم إدخال أنماطها إلى ANN (يتألف أي نمط من المماص المرافقة للمتغيرات).

تأخذ ANN بالاعتبار عناصر معالجة (PE) دخل بنفس عدد المتغيرات. تمتلك الطبقة الخفية PE واحد لكل صنف (6 من أجل المجموعة الأقل، و5 من أجل التراكيز الأعلى). بعد عدة محاولات سابقة لاعتبار طبقات خفية متعددة (من 1 إلى 4)، كلٌ بـــ PEs مختلفة (من 1 إلى 50)، تم تنفيذ مقارنة بين مستوي الملاءمة النهائي، الذي تم التوصل إليه بواسطة ANN والزمن اللازم لتدريبها. كانت هذه المقارنة جوهرية، لأنه على الرغم من أن النتائج الأفضل تم الحصول عليها بطبقات خفية أكثر، فإن الزمن اللازم للتدريب كان أعلى بكثير أيضاً. عندئذ، تم اتخاذ قرار بعدم تدريب الشبكة بشكل شامل، وإنما الحصول على مقاربة جيدة لأدائها الحقّيقي، وتوضيح فيما إذا كانت متغيرات الدخل مناسبة حقاً من أجل التصنيف الدقيق للعينات. النقطة الهامة هنا هي أن ANNs لديها نفس البنية، بحيث يصبح من الممكن مقارنة نتائجها.

يكمن الهدف في تحديد أي الحلول من بين تلك المزودة بالــ GA تمثل نقاط بداية جيدة، وبالتالي سيكون كافياً تحديد تعلّم ANN إلى تلك النقطة، حيث تبدأ ANN بالتقارب. من أجل هذه المسألة المحددة، بدأ التقارب بعد 800 دورة، وبغية ضمان الوصول إلى هذه الخطوة، تم تثبيت عدد الدورات ليكون 1000 دورة.

بغية تفادي تأثير القيمة الصغرى المحلية قدر الإمكان خلال التدريب، تمت إعادة كل دور تدريب ثلاث مرات ونُبذت النتائج الأسوأ.

يُستخدم MSE المُكتسب إحصائياً من التدريب الأفضل لتعيين الملاءمة للسلسلة الفردية الوراثية. تعتمد قيمة الملاءمة العامة على اختيار المتغيرات كما هو معروض.

البحث المُشذّب

عندما يتوجب تحديد ملاءمة سلسلة فردية ما، فإن تقييم معدل التصنيف الناجح لنموذج ANN يكون جزءاً فقط من المسألة (التي يمكن أن تُعنّون باستخدام MSE)؛ أما الجزء الآخر فهو مساعدة تلك السلاسل الفردية، بحيث تنفذ تصنيفاً مستوفٍ للشروط المطلوبة بالمتغيرات الأقل. لهذا، فإن الملاءمة لأية سلسلة فردية وراثية سوف تُصاغ بالمعادلة 4.

المعادلة 4.

تابع التقييم من أجل طريقة بحث مُشذّب

$$fit_{ind\,i} = MSE(ANNi) + \frac{\#\,I's\ genotype\ Indi}{176}$$

حيث أن: fit_{indi} – ملاءمة السلسلة الفردية i. #I's genotype Indi – عدد النمط النموذجي للسلسلة الفردية i.

البحث الثابت والأبحاث متعددة الشكلية

هنا، عدد المتغيرات ثابت سلفاً بحيث أنه لم يعد هناك حاجة للحد الثاني في المعادلة 4 (المعادلة 5).

المعادلة 5.

تابع التقييم لكلٍّ من طريقتي البحث الثابت ومتعدد الشكلية

$$fit_{Indi} = MSE\ (ANNi)$$

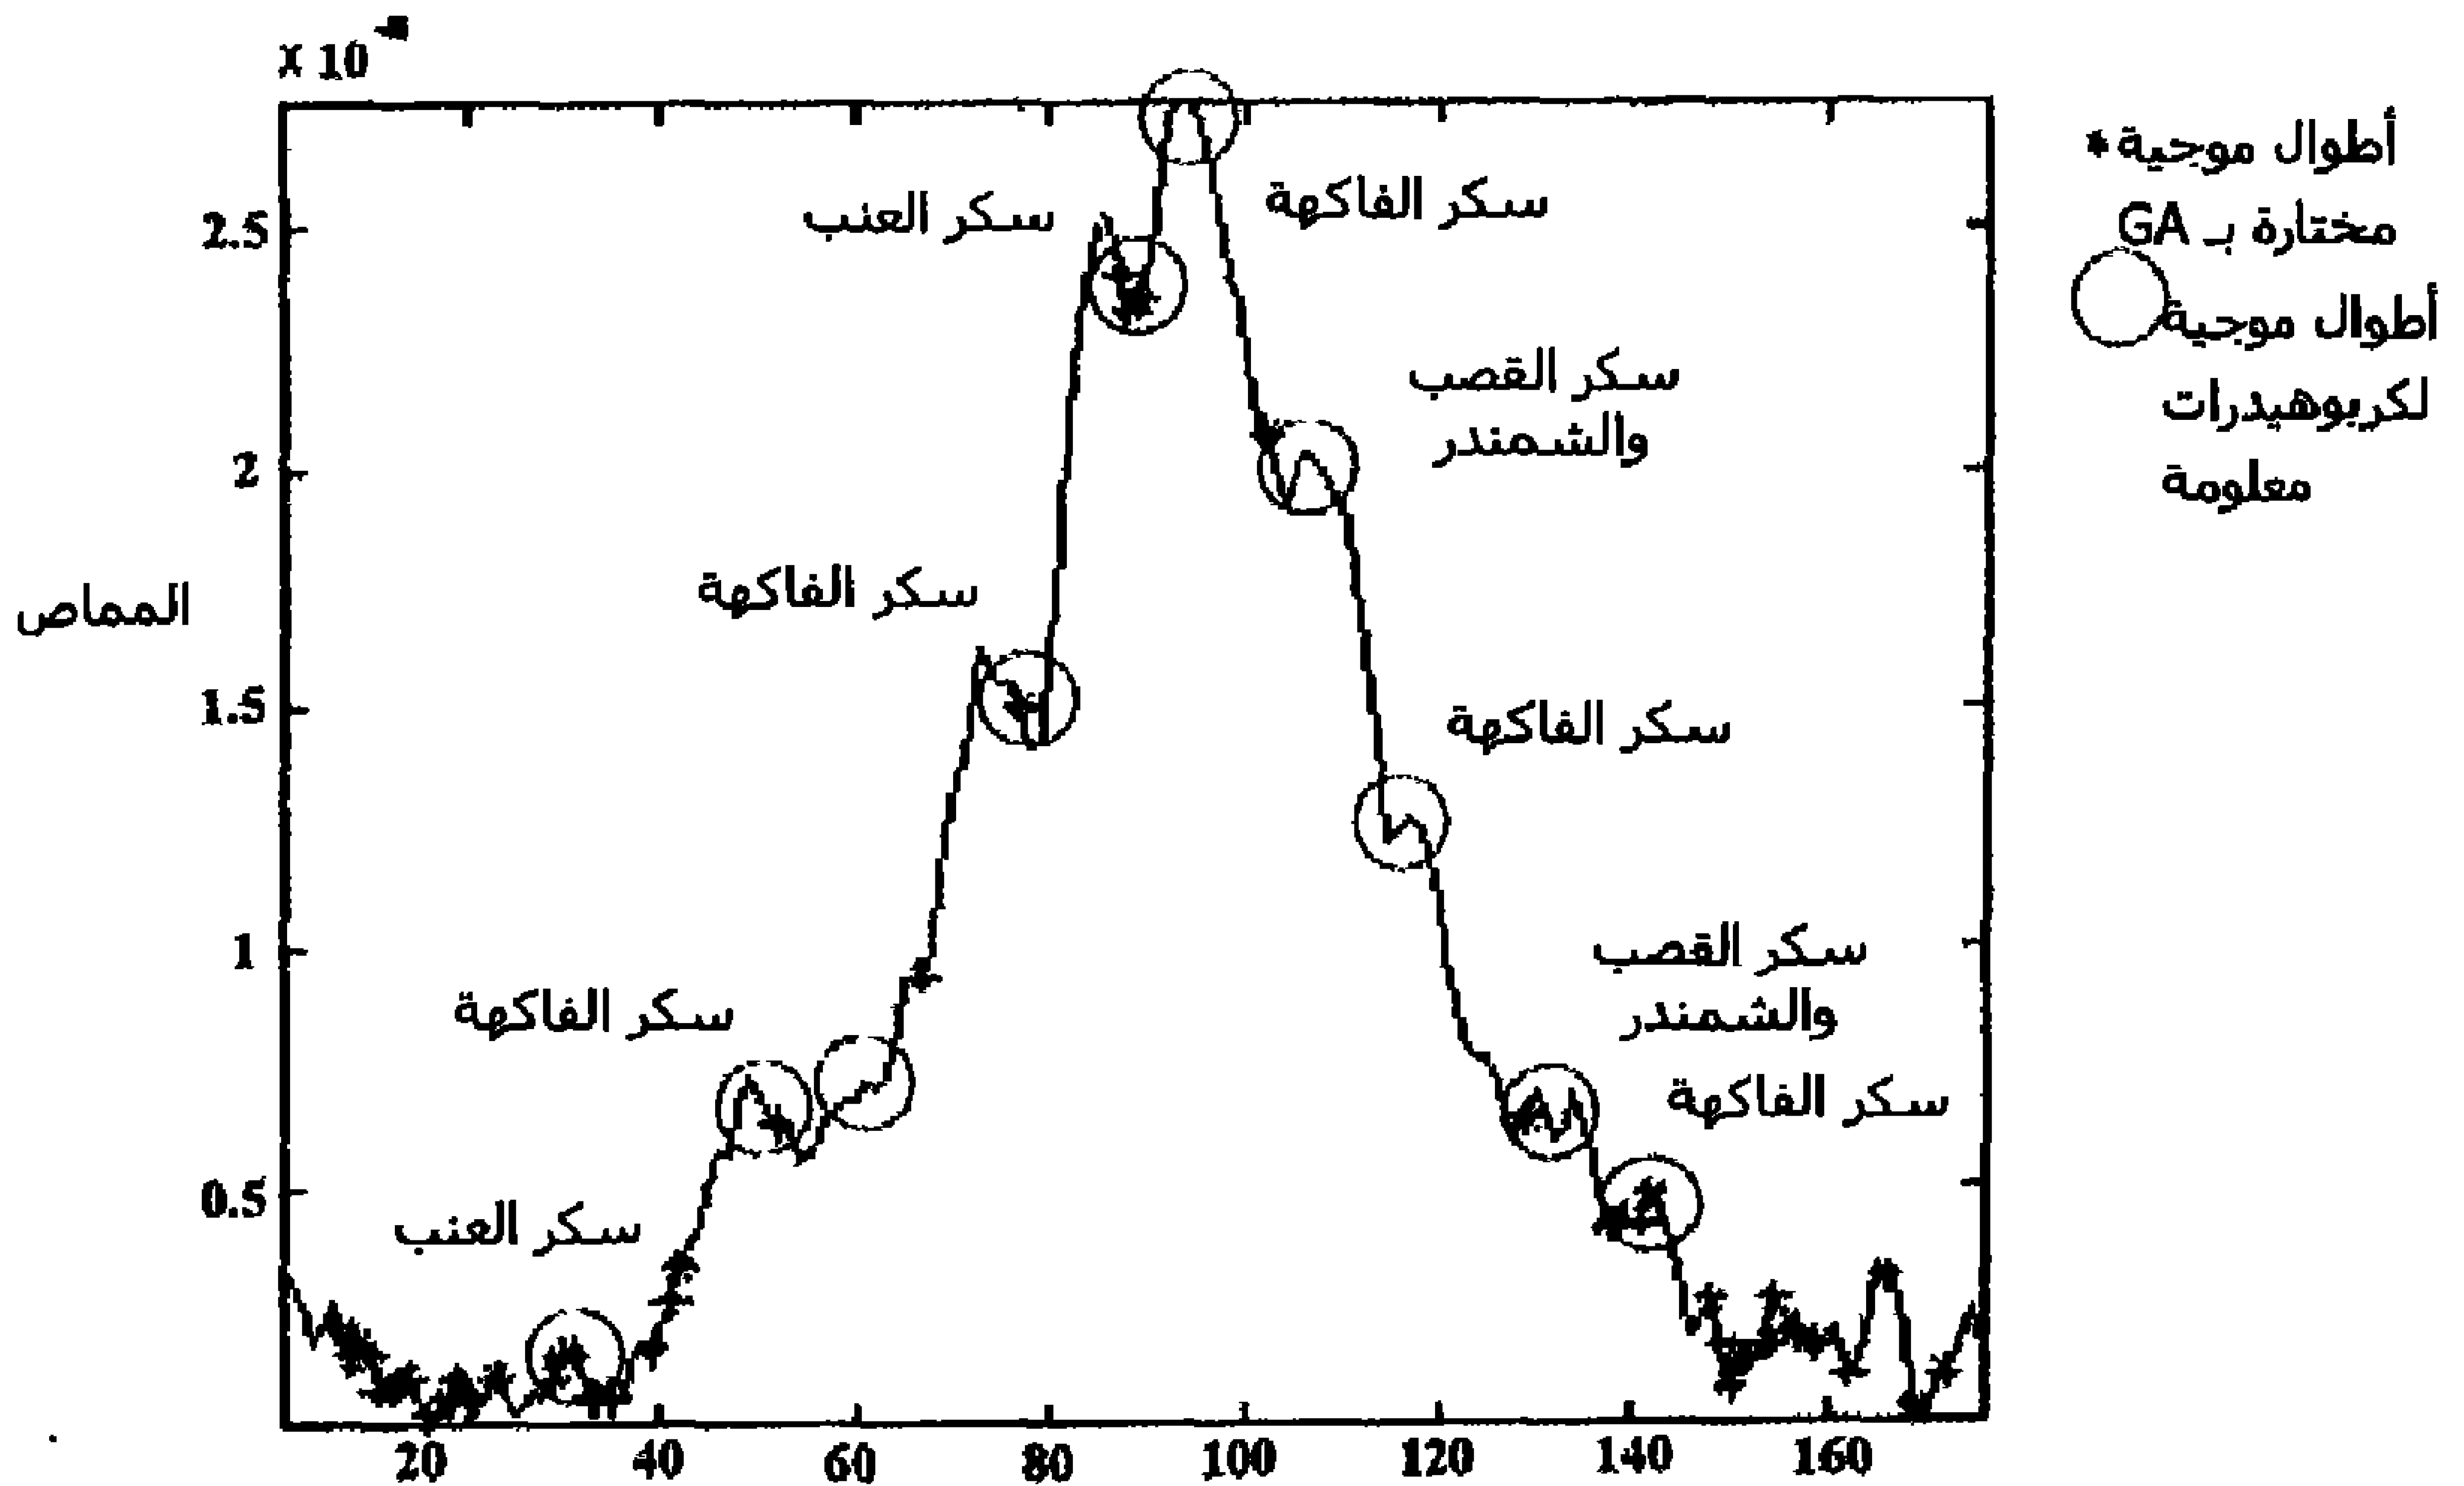
تنقية أبحاث GA بالتركيز على المتغيرات الهامة

كما هو معلوم جيداً، فإن أبحاث GA هي تقنيات بحث قوية قادرة على إيجاد الحلول الرياضية الجيدة حتى في حالات معقدة جداً، وهذا ينفذ تباعاً سلبية مفادها، أنه في العديد من الأوقات لا يستطيع المستخدم الأخير للمنهجية أن يفسر النتائج. وهذه قضية هامة، لأنه يجب فهم لماذا لم تُصنف عينة مفروضة بشكل صحيح، أو الأسوأ من ذلك، إذا كان التصنيف المعطى بمختبر الفحص لا يتوافق مع ذلك المُصرح به على اللصاقة. في حالة الدراسة المحددة هذه، يمكن أن

تكون المتغيرات الطيفية IR الأصلية مرتبطة كيميائياً بكربوهيدارات مختلفة (بشكل رئيسي سكريات). وبالتالي، فهناك حاجة لتأكيد الفهم الكيميائي لما يحصل، أو على الأقل للنتيجة النهائية. وظهر ذلك، بأنه ذو علاقة أكثر عندما استخدم البحث الثابت والبحث متعدد الشكلية.

وفقاً لذلك، اُدخل حد جديد على تقييم الملاءمة بغية تحقيق ذلك الهدف. تكون المتغيرات المرتبطة بالكربوهيدرات الرئيسية (سكر العنب) أو سكر الفواكه، أو سكر القصب والشمندر) معلومة مسبقاً، لذا، ستكوّن GA حوالي 10 مواقع للكربوهيدرات (الشكل 8). تُخزن المتغيرات العشرة التي تُحدد الكربوهيدرات في شعاع موقع الكربوهيدرات (لا تتغير خلال الاختبارات). الآن، يمكن أن تقيّم الملاءمة لأية سلسلة فردية ليس فقط بواسطة MSE، وإنما أيضاً من أجل المسافة بين كل مورثة من السلسلة الفردية والمواقع "النظرية" الأقرب للكربوهيدرات. إن السلاسل الفردية التي يكون من أجلها أي من تلك التوليفات أصغرية ستكون مقيدة. ويكمن الهدف الرئيس في أنه يتم الحصول على تفسير كيميائي مبسط إلى حد كبير طالما أن جودة التصنيف ما تزال جيدة. عندما تُقيّم الملاءمة بواسطة تابع تحقيق القيمة الصغرى، فسوف تكون السلاسل المفضلة هي التي تجعل القيمة أصغرية لكلٍّ من MSE والمسافة بين أحد المتغيرات المختارة وأحد المتغيرات النظرية في شعاع موقع الكربوهيدرات على الأقل، كما هو مبين في (الشكل 9).

الشكل (8) *متغيرات مختارة ومناطق متعلقة كيمياوياً بكربوهيدرات أساسية.*



الشكل (9) *الشيفرة الكاذبة لمعامل الطفرة.*

```
n Carbohydrates = 10        //   10 متغيرات كربوهيدراتية
Indi [1 ... n Genes]        //   السلسلة التي ستقييم
CPos [1 ... n Carbohydrates]   //   موقع الكربوهيدرات
min Pistance = Max_ INT        المسافة الصغرى = الرقم الأكبر
MSE ← ANN Classification error for Inditi   خطأ التصنيف لكل سلسلة فردية
For every g gene // g ∈ Indi        من أجل كل مورثةg
For every position p //        p ينتمي إلى موقع الكربوهيدرات
    Distgp = /Indi [q] - c Pos [p]/
    IF (Distgp <min Distance)
    THEN min Distance = Distgp
END FOR
ENDFOR
Fitness_i = MSE + min Distance/   الملائمة i = MSE + المسافة الصغرى
```

النتائج والمناقشة

بما أنه تلزم حالة مرجعية لتنفيذ المقارنات، فقد قُدمت أولاً نتائج التصنيف المنجزة باستخدام 176 من المتغيرات الأصلية (جدول 3)، تم الحصول عليها بأمْثلة نموذج ANN كالمعتاد (اختيار عدد الطبقات الخفية، عدد العصبونات في كل طبقة، معدل التعلّم، ... الخ).

لَزِم معيار خارجي بغية تحديد العدد الأصغر للمتغيرات، الذي يمكن أن يؤخذ بالاعتبار. هنا، تم استخدام خوارزمية دوران العالم Procrustes (Krzanowski, 2001)، واُعتبر أن المكونين الرئيسيين جيدان كفاية لوصف مجموعة البيانات (99.76 % من التشتت الكلي). وهكذا، يجب الوصول إلى متغيرين أصليين على الأقل.

التصنيف الذي يأخذ بالاعتبار كافة المتغيرات الأصلية

تم تنفيذ طرق تصنيف مختلفة مستخدمة نموذجياً في الكيمياء التحليلية (انظر الجدول 3). وقد اُستنتج، بأن مجموعة العينات بنسب مئوية منخفضة (2 % إلى 20 %) للعصير تكون صعبة ومعقدة أكثر بكثير كي تُصنّف من العينات بتراكيز أعلى (25 % إلى 100 %). في الواقع، كان عدد الأخطاء أعلى من أجل مجموعة 2 % إلى 20 % في كلٍّ من المعايرة والصلاحية.

إن تصنيف العينات التجارية متوافق تماماً مع النسب المئوية للعصير المُصرح بها على اللصاقات، ولكن من أجل عينة محددة. عندما دُرست تلك العينة بالتفصيل، تبين بأن طيفها مختلف بعض

الشيء عن العينات العادية. ويفترض هذا بأن العصير احتوى كمية عالية جداً من السكر (السكريات) المُضاف. إذا ما تمت مقارنة المعلومات المُكتسبة بطرق التصنيف المختلفة، فإنه يمكن القول، بأن النتائج الأفضل قد تحققت باستخدام ANN، والتي هي مفيدة جداً لعنونة عمليات اختيار المتغيرات باستخدام GA بتوابع ملاءمة معتمدة على ANN.

الجدول (3) التصنيفات باستخدام كافة المتغيرات الأصلية الـ 176.

تركيز	تدريب	صلاحية	تجاري
	PLS		
2%-20%	#LV = 2, n=134, #errors=29	n=39, #errors = 11	n=2, #errors=0
25%-100%	#LV = 2, n=86, #errors=11	n=44, #errors = 5	n=21, #errors=1
	SIMCA		
	عدد معاملات لكل صف		
2%-20%	2%: 1 4%:2 6%:3 8%:4		
	10%:2 16%:3 20%:4	n=39, #errors=14	n=2, #errors=0
	n=134, #errors=19		
	عدد معاملات لكل صفع		
25%-100%	20%:2 25%:2		
	70%:3 100%:4	n=44, #errors=12	n=21, #errors=1
	منحنيات كامنة		
2%-20%	PC1-PC2 معاملات فضاء جزئي		
25%-100%	n=134, #errors=4	n=39, #errors=9	n=2, #errors=0
	PC1-PC2 معاملات فضاء جزئي	n=44, #errors=6	n=21, #errors=0
	ANNs		
	ANN طبولوجية = 7/80+50/176		
2%-20%	Ir=0.0005 , mse Threshold=5	n=39, #errors=4	n=2, #errors=0
	n=134, #errors=0		
	ANN طبولوجية = 5/5+8/176		
25%-100%	Ir=0.001 , mse Threshold=1	n=44, #errors=1	n=21, #errors=0
	n=86, #errors=0		

n - عدد العينات، # - الأصلية، Lr = معدل التعلّم، LV - المتغيرات المستترة، mse threshold - عتبة MSE المستخدمة لإيقاف التدريب (إذا لم يتوقف بعد 500.000 دورة)، errors - الأخطاء.

التصنيف بعد البحث المُشذّب

يظهر (الجدول 4) بعض نتائج التصنيف المُكتسبة من نماذج ANN مختلفة باستخدام مجموعات من متغيرين مختارين باستراتيجية GA المعتمدة على البحث المُشذّب. مع الرغم أنه قد نُفذت عدة

محاولات، فإن (الجدول 4) يُظهر فقط الحالات الأكثر استيفاءً للشروط المطلوبة. وهي أسوأ من تلك الحالات الموجودة في (الجدول 1)، وخاصةً من أجل مجموعات بيانات الصلاحية. مع ذلك يبقى تصنيف العينات التجارية مستوفياً للشروط المطلوبة.

الجدول (4) نتائج التصنيف بعد البحث المُشذّب.

تركيز	تدريب	صلاحية	تجاري
	متغيرات مختارة: [42 77]		
2%-20%	طبولوجية ANN=2/10+60/7 Ir=0.001 , mse Threshold=5 n=134, #errors = 5	n=39, #errors = 16	N=2 ,#errors=1
25%-100%	طبولوجية ANN=2/10+60/5 Ir=0.001 , mse Threshold=5 n=86, #errors = 3	n=44, #errors = 9	N=21, #errors = 0
	متغيرات مختارة: [52 141]		
2%-20%	طبولوجية ANN=2/10+60/7 Ir=0.001 , mse Threshold=5 n=134, #errors = 19	n=39, #errors=17	N=2 ,#errors=2
25%-100%	طبولوجية ANN=2/10+60/5 Ir=0.001 , mse Threshold=5 n=86, #errors=4	n=44, #errors=8	N=21 ,#errors=1
	متغيرات مختارة: [129 102]		
2%-20%	طبولوجية ANN=2/10+60/7 Ir=0.001 , mse Threshold=5 n=134, #errors = 10	n=39, #errors=14	N=2 ,#errors=2
25%-100%	طبولوجية ANN=2/10+60/5 Ir=0.001 , mse Threshold=5 n=86, #errors = 3	n=44, #errors=10	N=21 ,#errors=0

n - عدد العينات، # الأصلية، Lr - معدل التعلّم، errors - الأخطاء، mse threshod - عتبة MSE المستخدمة لإيقاف التدريب (إذا لم يتوقف التدريب بعد 500.000 دورة).

كما تم أيضاً تنفيذ تصنيف نفس مجموعات البيانات بواسطة PLS وSIMCA والمنحنيات الكامنة باستخدام نفس الأزواج من المتغيرات. بالرغم من أنها غير مُفصلة هنا، فلقد تفوقت نماذج ANN (Gestal et at. 2005). وهذا محتمل، لأن GA تستخدم ANN لتقييم ملاءمة كل حل، وبالتالي تختار المتغيرات الأفضل لتقلل بالضبط التصنيف باستخدام ANN بعد ذلك. سوف نقدم فقط النتائج المكتسبة باستخدام ANN وفقاً لذلك.

التصنيف بعد البحث الثابت

لُخصت في (الجدول 5) ثلاثة حلول جيدة. كما في القسم السابق، ليس كافة المحاولات المُنفذة معروضة. ويمكن ملاحظة أن ANN تعطي نتائج أسوأ إلى حد كبير من تلك المكتسبة بالبحث المُشذب. ونفس الأمر قد حدث عندما حاولت طرق تصنيف أخرى. (تفاصيل أكثر حول ذلك مذكورة في (Gestal et at. 2005).

وقد أُستنتج بالتالي، أن طريقة البحث الثابت ليست طريقة مُرضية لاكتشاف المجموعة الأفضل من المتغيرات (في هذه الحالة، متغيرين). لدى طريقة البحث الثابت، الذي يأخذ بالاعتبار صبغيات بمورثتين، عيب مفاده أنه طالما أن أي معامل تصالب سيستخدم نقطة تصالب وحيدة متوفرة (بين المورثات)، فإن نصف المعلومات فقط من كلٍّ أب ستنقل إلى نسله. وهذا يحول طريقة البحث الثابت إلى بحث عشوائي، حيث أن مورثتان فقط تشكلان الصبغي.

في الواقع، قد لا يكون هذا النوع من البحث قادراً على ربط المتغيرين اللذين لا يمثلان حلين جيدين لوحدهما، و إنما يُنتج الحل الجيد حينما يكونا مُدمجين. بهذا المعنى، تعمل هذه الطريقة كمسألة خادعة (Goldberg, 1987).

التصنيف بعد بحث متعدد الشكلية

كما نُوقش سابقاً، يوجد حالات حيث يُستخلص النموذج النهائي بعد تحليل حلول مختلفة لنفس المسألة. في (الجدول 6) مُعطى مثال على ذلك. بعد تكرار التحليل عدة مرات (20 مرة)، تم ملاحظة أن الحلول قد رُكّزت على طول مناطق طيفية معينة. والأمر الذي كان إيجابياً بما فيه الكفاية، هو أن النتائج كانت أعلى بشكل واضح من تلك المُكتسبة بالبدائل السابقة.

التصنيف بعد بحث متعدد الشكلية بنقاط دراسة

أدت الطرق الثلاثة السابقة إلى نتائج متماثلة تماماً مشيرةً إلى وجود قاعدة (خفية)، قد تحدد أداءً كهذا. مع ذلك، لم يتم إيجاد أي علاقة أخرى بين المتغيرات غير الاتجاه يمكن استخلاصها من المناطق الطيفية، حيث يكون تشتت الإشارة أعلى على طول عينات المعيارية المختلفة، والذي - تباعاً - قد يكون المفتاح لتصنيف مستوف الشروط المطلوبة. تملك الفكرة خلفية كيميائية جيدة، على الرغم من أنه وبشكل مخيب للآمالً رُكزت العديد من المتغيرات على إحدى نهايات الطيف (الشكل 9). هذه المناطق متعلقة بشكل رئيسي، بالضجيج الطيفي (يملك الضجيج - بشكل تناسبي - تشتتاً كبيراً ولكن غير مرتبط بمسألة التصنيف).

الجدول (5) نتائج التصنيف بعد البحث الثابت.

تركيز	تدريب	صلاحية	تجاري
	متغيرات مختارة: [12 159]		
	ANN=2/10+60/7 طبولوجية		
2%-20%	Ir=0.001 , me =5	n=39, #errors = 16	n=2 ,#errors=2
	n=134, #errors = 9		
	ANN=2/10+60/5 طبولوجية		
25%-100%	Ir=0.001 , me =5	n=44, #errors = 12	n=21, #errors = 2
	n=86, #errors = 4		
	متغيرات مختارة: [23 67]		
	ANN=2/10+60/7 طبولوجية		
2%-20%	Ir=0.001 , mse Threshold=5	n=39, #errors=16	n=2 ,#errors=1
	n=134, #errors = 5		
	ANN=2/10+60/5 طبولوجية		
25%-100%	Ir=0.001 , mse Threshold=5	n=44, #errors=12	n=21 ,#errors=2
	n=86, #errors=3		
	متغيرات مختارة: [102 129]		
	ANN=2/10+60/7 طبولوجية		
2%-20%	Ir=0.001 , mse Threshold=5	n=39, #errors=14	n=2 ,#errors=2
	n=134, #errors = 10		
	ANN=2/10+60/5 طبولوجية		
25%-100%	Ir=0.001 , mse Threshold=5	n=44, #errors=10	n=21 ,#errors=0
	n=86, #errors = 3		

n - عدد العينات، # الأصلية. Lr - معدل التعلّم، errors - الأخطاء، msethrehold - عتبة MSE المستخدمة لإيقاف التدريب (إذا لم يتوقف التدريب بعد 500.000 دورة).

لتفادي هذه المشكلة، أجبرت GA على تخطي تلك المتغيرات التي تكون أدلتها أصغر من 25 أو أكبر من 140. وأُعيد تنفيذ البحث متعدد الشكلية من جديد. ما إن تم تفادي المتغيرات الأكثر ضجيجاً، حتى أُدخل تعديلٌ ثان لتحسين الفهم الكيميائي لما حصل. وبدون جدوى، فقد تم ملاحظة ولعدة مرات بأن المتغيراتٍ المختارة ليس لها معنى كيميائي. وبالتالي، لا يمكننا تعيين ما هي الكربوهيدرات التي حدد بدقة كمية عصير التفاح في المشروبات. بغية حل هذه القضية الكيميائية الرئيسة، تم تغذية GA بمعلومات متعلقة بالمناطق الطيفية، التي يمكن أن تكون مرافقة

بشكل محدد للكربوهيدرات الأكثر أهمية (الشكل 9). وبهذا الأسلوب، سوف تفضل GA تلك السلاسل الفردية التي تكون متغيراتها قريبة من تلك الكربوهيدرات. يوجز (الجدول 7) النتائج لعدة دراسات. يمكن ملاحظة أن نجاح التصنيف مشابه - أو حتى أعلى بعض الشيء – لذلك المُكتسب بالبحث متعدد الشكلية لوحده. ولكن الكربوهيدرات (السكر/السكريات) المسؤولة عن نموذج التصنيف الآن معلومة.

الجدول (6) نتائج التصنيف بعد بحث متعدد الشكلية.

تركيز	تدريب	صلاحية	تجاري
متغيرات مختارة: [89 102]			
2%-20%	ANN=2/10+60/7 طبولوجية Ir=0.001 , mseThreshold =2 n=134, #errors = 7	n=39, #errors = 10	n=2 ,#errors=2
25%-100%	ANN=2/10+60/5 طبولوجية Ir=0.001 , mseThreshold =2 n=86, #errors = 3	n=44, #errors = 8	n=21, #errors = 0
متغيرات مختارة: [7 ׀ 102]			
2%-20%	ANN=2/10+60/7 طبولوجية Ir=0.001 , mse Threshold=2 n=134, #errors = 4	n=39, #errors=11	n=2 ,#errors=2
25%-100%	ANN=2/10+60/5 طبولوجية Ir=0.001 , mse Threshold=2 n=86, #errors=3	n=44, #errors=7	n=21 ,#errors=0
متغيرات مختارة: [3 ׀ 89]			
2%-20%	ANN=2/10+60/7 طبولوجية Ir=0.001 , mse Threshold=2 n=134, #errors = 14	n=39, #errors=10	n=2 ,#errors=2
25%-100%	ANN=2/10+60/5 طبولوجية Ir=0.001 , mse Threshold=2 n=86, #errors = 4	n=44, #errors=4	n=21 ,#errors=0

n - عدد العينات، # الأصلية، Lr - معدل التعلّم، errors - الأخطاء، mse threshold - عتبة MSE المستخدمة لإيقاف التدريب (إذا لم يتوقف التدريب بعد 500.000 دورة).

الجدول (7) نتائج التصنيف بعد بحث متعدد الشكلية بنقاط دراسة.

تركيز	تدرب	صلاحية	تجاري
	متغيرات مختارة: [88 92]		
2%-20%	ANN=2/10+60/7 طبولوجية Ir=0.001 , mseThreshold =2 n=134, #errors = 7	n=39, #errors = 9	n=2 ,#errors=2
25%-100%	ANN=2/10+60/5 طبولوجيه Ir=0.001 , mseThreshold =2 n=86, #errors = 3	n=44, #errors = 8	n=21, #errors = 0
	متغيرات مختارة: [88 102]		
2%-20%	ANN=2/10+60/7 طبولوجيه Ir=0.001 , mse Threshold=2 n=134, #errors = 4	n=39, #errors=10	n=2 ,#errors=2
25%-100%	ANN=2/10+60/5 طبولوجية Ir=0.001 , mse Threshold=2 n=86, #errors=3	n=44, #errors=7	n=21 ,#errors=0
	متغيرات مختارة: [85 102]		
2%-20%	ANN=2/10+60/7 طبولوجيه Ir=0.001 , mse Threshold=2 n=134, #errors = 0	n=39, #errors=11	n=2 ,#errors=2
25%-100%	ANN=2/10+60/5 طبولوجية Ir=0.001 , mse Threshold=2 n=86, #errors = 2	n=44, #errors=7	n=21 ,#errors=0

n - عدد العينات، # الأصلية، Lr - معدل التعلّم، errors - الأخطاء. mse threshold - عتبة MSE المستخدمة لإيقاف التدريب (إذا لم يتوقف التدريب بعد 500.000 دورة).

الاستنتاجات

يمكن الخلوص إلى عدة استنتاجات من النتائج المكتسبة باستخدام الاقتراحات المختلفة لاختيار المتغيرات:

- تم إيضاح بأن تقنيات EC، وبشكل خاص GA، هي طريقة صالحة لتنفيذ اختيار المتغيرات، طالما أن نتائجها مقبولة عموماً.

- نجاح التصنيف لطريقة البحث المُشذّب أكبر من مثيله لطريقة البحث الثابت. وهذا يمكن تفسيره بسبب إمكانية ربط المتغيرات، التي يمكن أن تعطي معاً نتيجةً جيدة تكون أقل عند امتلاك الصبغي لمورثتين فقط من الحالة عندما – على النقيض من ذلك – يُطبق بحث متسلسل – مُشذّب. في الحالة الأخيرة، تُنفذ إزالة متدرجة للمتغيرات حتى (في الحالة الدراسية المقدمة هنا) الإبقاء على المتغيرين الأكثر أهمية.
- تم الحصول على أفضل النتائج باستخدام GA متعددة الشكلية. ربما كان ذلك بسبب قدرتها على المحافظة على تنوع المجتمع الوراثي. لا يحث هذا التنوع على ظهور الحلول المثالية فقط، وإنما يتفادى أن يتوقف البحث عند قيمة صغرى محلية. لايعطي هذا الخيار حلاً واحداً فقط، وإنما مجموعة من الحلول بملاءمة متماثلة. يسمح ذلك للكيميائيين باختيار حل بخلفية كيميائية صوتية (عميقة). خاصة وأنه توجد طريقة جذابة جداً تعمل على تضمين "نقاط الدراسة" في استراتيجة البحث GA المسماة HTP-GA.

المراجع

Braakman, L. (2005). What to get ready for. Food Engineering & Ingredients, 27(6), 14-19.

Darwin, C. (1859). On the origin of species by means of natural selection.

DeJong, K.A. (1975). An analysis of the behavior of a class of genetic adaptative systems. Ph.D. dissertation, University of Michigan.

Dorado, J., Rabuñal, J.R., Pazos, A., Santos, A., & Pedreira, N. (2002). Algoritmo genético de dos poblaciones para búsqueda homogénea en el espacio de soluciones. Proceedings of L Congreso Nacional de Algoritmos Evolutivos y Bioinspirados (AEB '02), Mérida, Spain (pp. 241 -245).

Forina, M.,Armanino, C.,Learde, R.,&Drava,G.(1991). A class-modelling technique based on potential functions. J. Chemometrics, 5, 435-453.

Gestal, M., Gómez-Carracedo, M.P., Andrade, J.M., Dorado, J., Fernandez, E., Prada, D., & Pazos, A. (2004). Classification of apple beverages using artificial neural networks with previous variable selection. Analytica Chimica Acta, 225-234.

Gestal, M., Gómez-Carracedo, M.P., Andrade, J.M., Dorado, J., Fernández, E., Prada, D., & Pazos, A. (2005). Selection of variables by genetic algorithms to classify apple beverages by artificial neural networks. Applied Artificial Intelligence, 181-198.

Gestal, M., Rabuñal, J.R., Dorado, J., & Pazos A. (2004). Exploración sistemática del espacio de búsqueda mediante un algoritmo genético de 2 poblaciones. Proceedings of III Congreso Nacional de Metaheurísticas, Algoritmos Evolutivos y Bioinspirados (MAEB'04), Córdoba, Spain (pp. 286-291).

Gnanadesikan, R. (1997). Methods for statistical data analysis of multivariate observations. New York: John Wiley & Sons.

Goldberg, D. (1987). Simple genetic algorithms and the minimal deceptive problem. In L. Davis (Ed.), Genetic algorithms and simulated annealing (pp. 74-88). London.

Goldberg, D. (1989). Genetic algorithms in search, optimization and machine learning. Addison-Wesley.

Harik, G. (1995). Finding multimodal solutions using restricted tournament selection. Proceedings of the Sixth International Conference on Genetic Algorithms (ICGA 95) (pp. 24-31).

Jain, A.K., Murly, M.N., & Flynn, P.J. (1999). Data clustering: A review. ACM Computing Surveys, 31(3), 264-323.

Jamin, E., Gonzalez, J., Remaud, G., Naulet, N., & Martin, G. (1997). Journal of Agricultural Food Chemistry, 45(10), 3961 -3967.

Krzanowski, W.J. (2001). Principles of multivariate analysis: A user's perspective. New York: Oxford University Press.

Saavedra, L., García, A., & Barbas, C. (2000). Journal of Chromatography Analitycal, 395-401.

Sareni, B., & Krähenbuhl. (1998). Fitness sharing and niching methods. IEEE Transactions on Evolutionary Computation, 2(3), 97-106.

Stöber, P., Martin, G., & Pepper, T.L. (1998). Deutsche Labensmittel-Rundschau, 94(9), 309-316.

Tomás i Morer, X., & Andrade Garda, J.M. (1999). Application of simplified potential curves to classification problems. Química Analítica 18, 117-120.

Tomassini, M. (1995). A survey of genetic algorithms. Annual Reviews of Computational Physics Vol. III, World Scientific, 87-117.

Whitley, D., Beveridge, J.R., Guerra-Salcedo, C., & Graves, C. (1997). Messy genetic algorithms for subset feature selection. Proceedings of the Seventh International Conference on Genetic Algorithms (ICGA97) (pp. 568-575).

Wold, S., Johansson, E., Jellum, E., Bjørnson, I., & Nesbakken, R. (1981). Application of SIMCA multivariate data analysis to the classification of gas chromatographic profiles of human brain tissues. Analytica Chimica Acta 133, 251-159.

Yuan, J.P., & Chen, F. (1999). Food chemistry, 64,423-427.

القسم 4

الهندسة المدنية

الفصل الثامن

نظام هجين من الشبكات العصبونية الصنعية والحوسبة التطورية في الهندسة المدنية

ملخص

يقترح هذا الفصل تطبيق تقنيتي ذكاء صنعي في مجال الهندسة المدنية هما: الشبكات العصبونية الصنعية (ANNs) والحوسبة التطورية (EC). تم في هذا الفصل تبيان كيف يمكن لهاتين التقنيتين أن تعملا سوية بغية حل مسألة ما في الهيدرولوجي (علم المياه). تشمل هذه المسألة نمذجة تأثير المطر على الجريان السطحي في حوض صرف مدينة نموذجي. ويكمن الهدف الأساسي في تصميم نظام إنذار بزمن حقيقي لتحذير الفيضانات أو الهبوطات في أنواع مختلفة من أحواض صرف المدينة. وقد ضُمنت حالة دراسية بمثابة مثال.

مقدمة

جافظت والتطورات في مجال الذكاء الصنعي على امتلاك تأثير قوي على مجال الهندسة المدنية، حيث تنبثق طرق وخوارزميات جديدة تمكّن المهندسين المدنيين من استخدام الحاسبات في نواحي مختلفة، وإحدى تلك النواحي هي مجال الهيدرولوجي (علم المياه).

الهيدرولوجي هو العلم الذي يدرس خصائص حركة المياه الأرضية فيما يتعلق باليابسة (بالأرض). فحوض النهر هو منطقة صُرّفت بالأنهار والروافد. والجريان السطحي هو كمية هطول المطر التي تُحمل بعيداً عن تلك المنطقة بالجداول والأنهار. خلال دراسة حوض مدينة، تم استبدال الجداول والأنهار بنظام مياه المجاري. يتأثر أي حوض مدينة بأنماط استهلاك سكان المدينة للمياه. إن نمذجة تدفق الجريان السطحي في حوض مدينة نموذجي هو الجزء من الهيدرولوجي، الذي يهدف إلى نمذجة شبكات المجاري. وهو يهدف لتوقع خطر ظروف المطر من أجل الحوض، ولدق جرس الإنذار للحماية من الفيضان أو الانهيار. يكمن هدف المهندسين في

بناء نظام مستقل ذاتياً وذاتي التكيف تماماً، يشكل توقعات فورية (بزمن حقيقي) لتغير مناسيب المياه مزود بأجهزة إنذار يمكنها أن تنذر السلطات بأخطار الفيضانات.

يقترح هذا الفصل تطبيق تقنيتي ذكاء صنعي في الهيدرولوجي هما: الشبكات العضوية الصنعية (ANNs) والحوسبة التطورية (EC). سنبيّن كيف يمكن أن تعمل هاتان التقنيتان معاً لحل مسألة ما، وتحديداً من أجل نمذجة تأثير المطر على تدفق الجريان السطحي في حوض مدينة نموذجي. يكمن الهدف النهائي لهذا الفصل في تصميم نظام إنذار في الزمن الحقيقي للتحذير من الفيضانات أو الانهيار في أنواع مختلفة من أحواض المدينة. تبدو النتائج واعدة وتظهر بعض التحسينات من أجل تحليل أنظمة الأحواض النهرية على بعض الطرق الأخرى مثل المخططات المائية (المخطط المائي) الوَحْديّة.

خلفية

وصف المسألة

تتضمن المسألة قياس وتوقع التدفق المعتمد على المطر لحوض مدينة نموذجي بواسطة حساس متوضع في مجرور المدينة. تُستخدم إشارتان من أجل النمذجة: ترد الإشارة الأولى من مقياس كمية المطر، وتقيس الإشارة الثانية منسوب التدفق في المجرور. نُفذت على كلٍّ من الإشارة الموافقة للتدفق والأخرى الموافقة لمقياس المطر عملية أخذ عينات بمجالات مدتها خمس دقائق.

بعد ذلك، يعتبر البحث تحويل الجريان السطحي لهطول المطر حالة واضحة، يُحوّل فيها أحد المتغيرات (هطول المطر) إلى متغير آخر (التفريغ المتدفق عبر مجرور). يتضمن تابع التحويل شروطاً مختلفة مثل درجات ميل الشوارع، عدم انتظام سطوح الأرصفة غير، أنواع السقوف... وهلم جراً. تجعل هذه الشروط من المستحيل تحديد معادلة قادرة على نمذجة سير قطرة ماء من لحظة هطولها إلى اللحظة التي تدخل فيها إلى شبكة الصرف، لأن سير الماء عبر الشبكة معقد جداً.

هناك طرق عديدة لحساب عملية الجريان السطحي لهطول المطر (Viessmann et at., 1989). تعتمد بعض الطرق على استخدام توابع نقل تدعي عادةً "مخططات وحديّة Unit Hydrographs" ومُقرّة بالتجربة. أما الطرق الأخرى فتعتمد على معادلات هيدروليكية ذات بارامترات، ثابتة باستخدام الخصائص المورفولوجية لمجال الدراسة (موجة سينمائية). تزود الحزم البرمجية التجارية لحساب شبكات المجارير عادةً كلا النموذجين "المخططات الوحدّية" و"الموجة السينمائية".

إن استخدام طرق التنبؤ غير المعتمدة على معادلات فيزيائية – مثل ANN والبرمجة الوراثية (GP) – أصبح واسع الانتشار في مجالات مختلفة في الهندسة المدنية والهيدروليكية. والعملية التي نتعامل معها مناسبة جداً لهذا النوع من الحساب.

الشبكات العصبونية الصنعية

الشبكات العصبونية الصنعية (ANN) هي نظام معالجة معلومات، يعتمد على تعاميم الإدراك البشري أو علم الأحياء العصبي، وهي نماذج الكترونية أو حسابية معتمدة على البنية العصبونية للدماغ. يتعلم الدماغ بشكل أساسي من التجارب. هناك نوعان من ANN: يكون الأول فقط باتصالات أمامية الانتشار وتدعى ANN أمامية الانتشار، أما النوع الآخر فيكون باتصالات عشوائية بدون أي اتجاه وهو ما يُدعى غالباً بـ ANN التكرارية (RANN). يتألف النوع الأكثر شيوعاً من ANN من طبقات مختلفة مع بعض العصبونات في كلٍ منها ومتصلة بالاتصالات أمامية الانتشار ومُدرّبة بخوارزمية الانتشار الخلفي (Johansson et.at., 1992).

تملك أي ANN قدرة رائعة لاشتقاق المعنى من بيانات معقدة أو غير دقيقة. يمكن أن تستخدم ANN لاستخلاص الأنماط، وكشف الاتجاهات التي يصعب ملاحظتها من قبل البشر أو التقنيات الحاسوبية الأخرى. يمكن اعتبار أي ANN مدربة "كخبير" في فئة المعلومات، التي تم استعلامها للتحليل. يوجد هناك ميزتان لـ ANN هما:

- **التعلّم التكيفي**: القدرة على تعلّم كيفية تنفيذ المهام المعتمدة على البيانات المعطية للتدريب.
- **تحمل الخلل** (**العمل بشكلٍ مُرضٍ رغم عطل طارئ**): يؤدي الإتلاف الجزئي للشبكة إلى تدنٍّ في الأداء.

على أية حال، يمكن أن يُحافظ على بعض مقدرات الشبكة حتى بوجود ضرر رئيس للشبكة. وقد تم إظهار أن ANNs هي أداة قوية في العديد من التطبيقات المختلفة، بَيْدَ أن لديها مشكلة كبيرة، إذ أنه لا يمكن شرح عمليتها الاستنتاجية، بمعنى أنه لا توجد علاقة واضحة بين المدخلات المقدمة للشبكة والمخرجات التي تعطيها.

تم استقصاء مجال واسع من التطبيقات في مجال إدارة الموارد المائية (مشروع بحث مشترك IHE_STOWA، www.stowa-nn.ihe.nl). يمكن أن تُطبق ANN من أجل التنبؤ، المحاكاة، التصنيف، والأمْثلة (Schulze & Bouma, 2000). إذا كانت المتغيرات الهامة معلومة، ولكن علاقاتها الدقيقة غير معروفة، فإن ANN تستطيع تنفيذ نوع من ملاءمة التابع باستخدام بارامترات متعددة على المعلومات المتوفرة، وتوقع العلاقات المحتملة للمستقبل القادم، يتضمن

هذا النوع من المسائل توقع الجريان السطحي لهطول المطر، ومنسوب المياه، وعلاقات التفريغ، ومطلب الماء الصالح للشرب، والتدفق ونقل الرواسب، وتوقع جودة الماء .... وهلم جراً.

بعض أمثلة استخدام ANN هي التالية:

- إن توقع استهلاك الماء لجماعة من السكان ليس مهمة سهلة بسبب تأثير عدة عوامل. بحث العالم Aafjes etat. (1997) توقعاً قصير الأمد لاستهلاك جماعة للماء بواسطة ANN ، بواسطة نظام خبير تقليدي، وبواسطة توليفة من ANN ونظام خبير. وقد اُستخدمت بيانات استهلاك المياه لسنتين من أجل الدراسة.
- التحكم بعملية معالجة الماء هي عملية لا خطية إلى حد كبير. وقد اُستخدمت ANN من أجل التحكم بعمليات التخثر – التندُّف – الترسّب، وأيضاً من أجل اكتشاف الجرعة الكيمائية المثالية على أساس بارامترات جودة المياه الواردة (Zhang & Stanley, 1999).
- تم بحث توقع كلٍّ من منسوب الماء والتدفق النهري في حالة مُحددة لنهر النيل في مصر (Atiya et at. 1999). يمكن أن يكون لتقدير التدفق النهري تأثير اقتصادي هام بشكل رئيسي بخصوص إدارة المياه الزراعية، والحماية من نقص المياه، ومن ضرر الفيضان المحتمل.

أمثلة الدراسات في توقع الجريان السطحي لهطول المطر هي الآتية:

- درس العالم Loke et at. (1997) تطبيق ANN من أجل توقع الجريان السطحي باستخدام بيانات مصب (منطقة تجميع) بسيطة. تتألف بيانات الدخل لـــ ANN من خصائص المصب التقليدي مثل حجم المصب أو النسبة المئوية للمنطقة غير المُنفذة للماء، والتي يمكن أن تُشتق بسهولة من الخرائط الطبوغرافية الطبيعية. بقياسات مأخوذة من مقياسي مطر في كوبنهاغن، تم تحديد القياس المأخوذ من مقياس مطر ثالث. وقورنت النتائج بطريقة تعويض بسيطة، ووضحت النتيجة المقنعة المكتسبة قدرة ANN على التعامل مع هذا النوع من المسائل.
- استخدم العالم Sinak et at. (1995) شبكة التابع الشعاعي الأساسي (RBF) وشبكات الارتباط التعاقبي (CC) من أجل التنبؤ بتدفق المجرور على أساس بيانات هطول المطر التاريخية.

تم قياس البيانات لتدفقات المجرور بشكل مستمر من قبل حساسات منسوب فوق صوتية في ثلاثة نقاط من مقطع عرضي في نظام المجرور. وأُخذ قياس بيانات هطول المطر من مقياس المطر الموجود في مركز المدينة. الشبكة العصبونية CC هي نوع خاص من ANN ذات الانتشار الخلفي للخطأ، التي كان أداؤها في توقع تدفق المجرور أفضل من أداء شبكة RBF. تكمن ميزة الشبكة العصبونية CC في أنها تحقق أَمْثلة الطبولوجية بنفسها.

البرمجة الوراثية

البرمجة الوراثية (GP) هي طريقة تطورية تخلق برامج حاسوبية لتمثيل الحلول التقريبية أو الدقيقة لمسألة ما. تسمح هذه التقنية بإيجاد برامج بشكل شجرة، وهذه البرامج في تطبيقاتها الأكثر شيوعاً عبارة عن تعابير رياضية، تضم معاملات رياضية ومتغيرات دخل، وثوابت، وقواعد قرار ومعاملات ربطية.

يجب أن تُعيّن كل هذه المعاملات قبل البدء بالبحث، كما يجب أن تكون GP قادرة بها على بناء أشجار بغية إيجاد التغيير المطلوب، الذي قد يشكل العلاقة بين متغيرات الدخل والخرج المطلوب. تُقسم هذه المجموعة من المعاملات إلى مجموعتين: المجموعة الطرفية بمعاملات لايمكنها قبول البارامترات كالمتغيرات والثوابت، ومجموعة التابع بالمعاملات التي تحتاج لبارامترات مثل معامل الضرب والطرح. حينما تُحدد المجموعات، يصبح من الممكن تعيين الأنواع: تمتلك كل عقدة نوعاً معيناً، ويحتاج بناء تعابير الابن اتباع قواعد نوع العقدة (Montana, 1995).

تشكل GP عملية توليد برنامج آلي بالاعتماد على نظرية التطور لداروين (Darwin, 1859)، التي يُنتج فيها بعد توليدات متلاحقة أشجار جديدة (سلاسل فردية) من الأشجار القديمة بواسطة التصالب والنسخ والطفرة (Fuchs, 1998; Luke, & Spector, 1998). كما يحدث في الاصطفاء الطبيعي: يكون للأشجار الأفضل فرص أكبر، كي تُختار لتصبح جزءاً من الجيل التالي. وهكذا، تُؤسس عملية عشوائية يتم الحصول فيها (بعد توليدات متتابعة) على شجرة مُتكيفة بشكل جيد.

الطرق الهيدروليكية

بالتركيز على عملية انتقال الجريان السطحي لمياه الأمطار، تلاحظ فلسفات حسابية مختلفة. ستُناقش منها هنا الاثنتان الأكثر تطبيقاً بشكل عام وهما: المخطاطات المائية الوَحْديّة، والطرق الهيدروليكية.

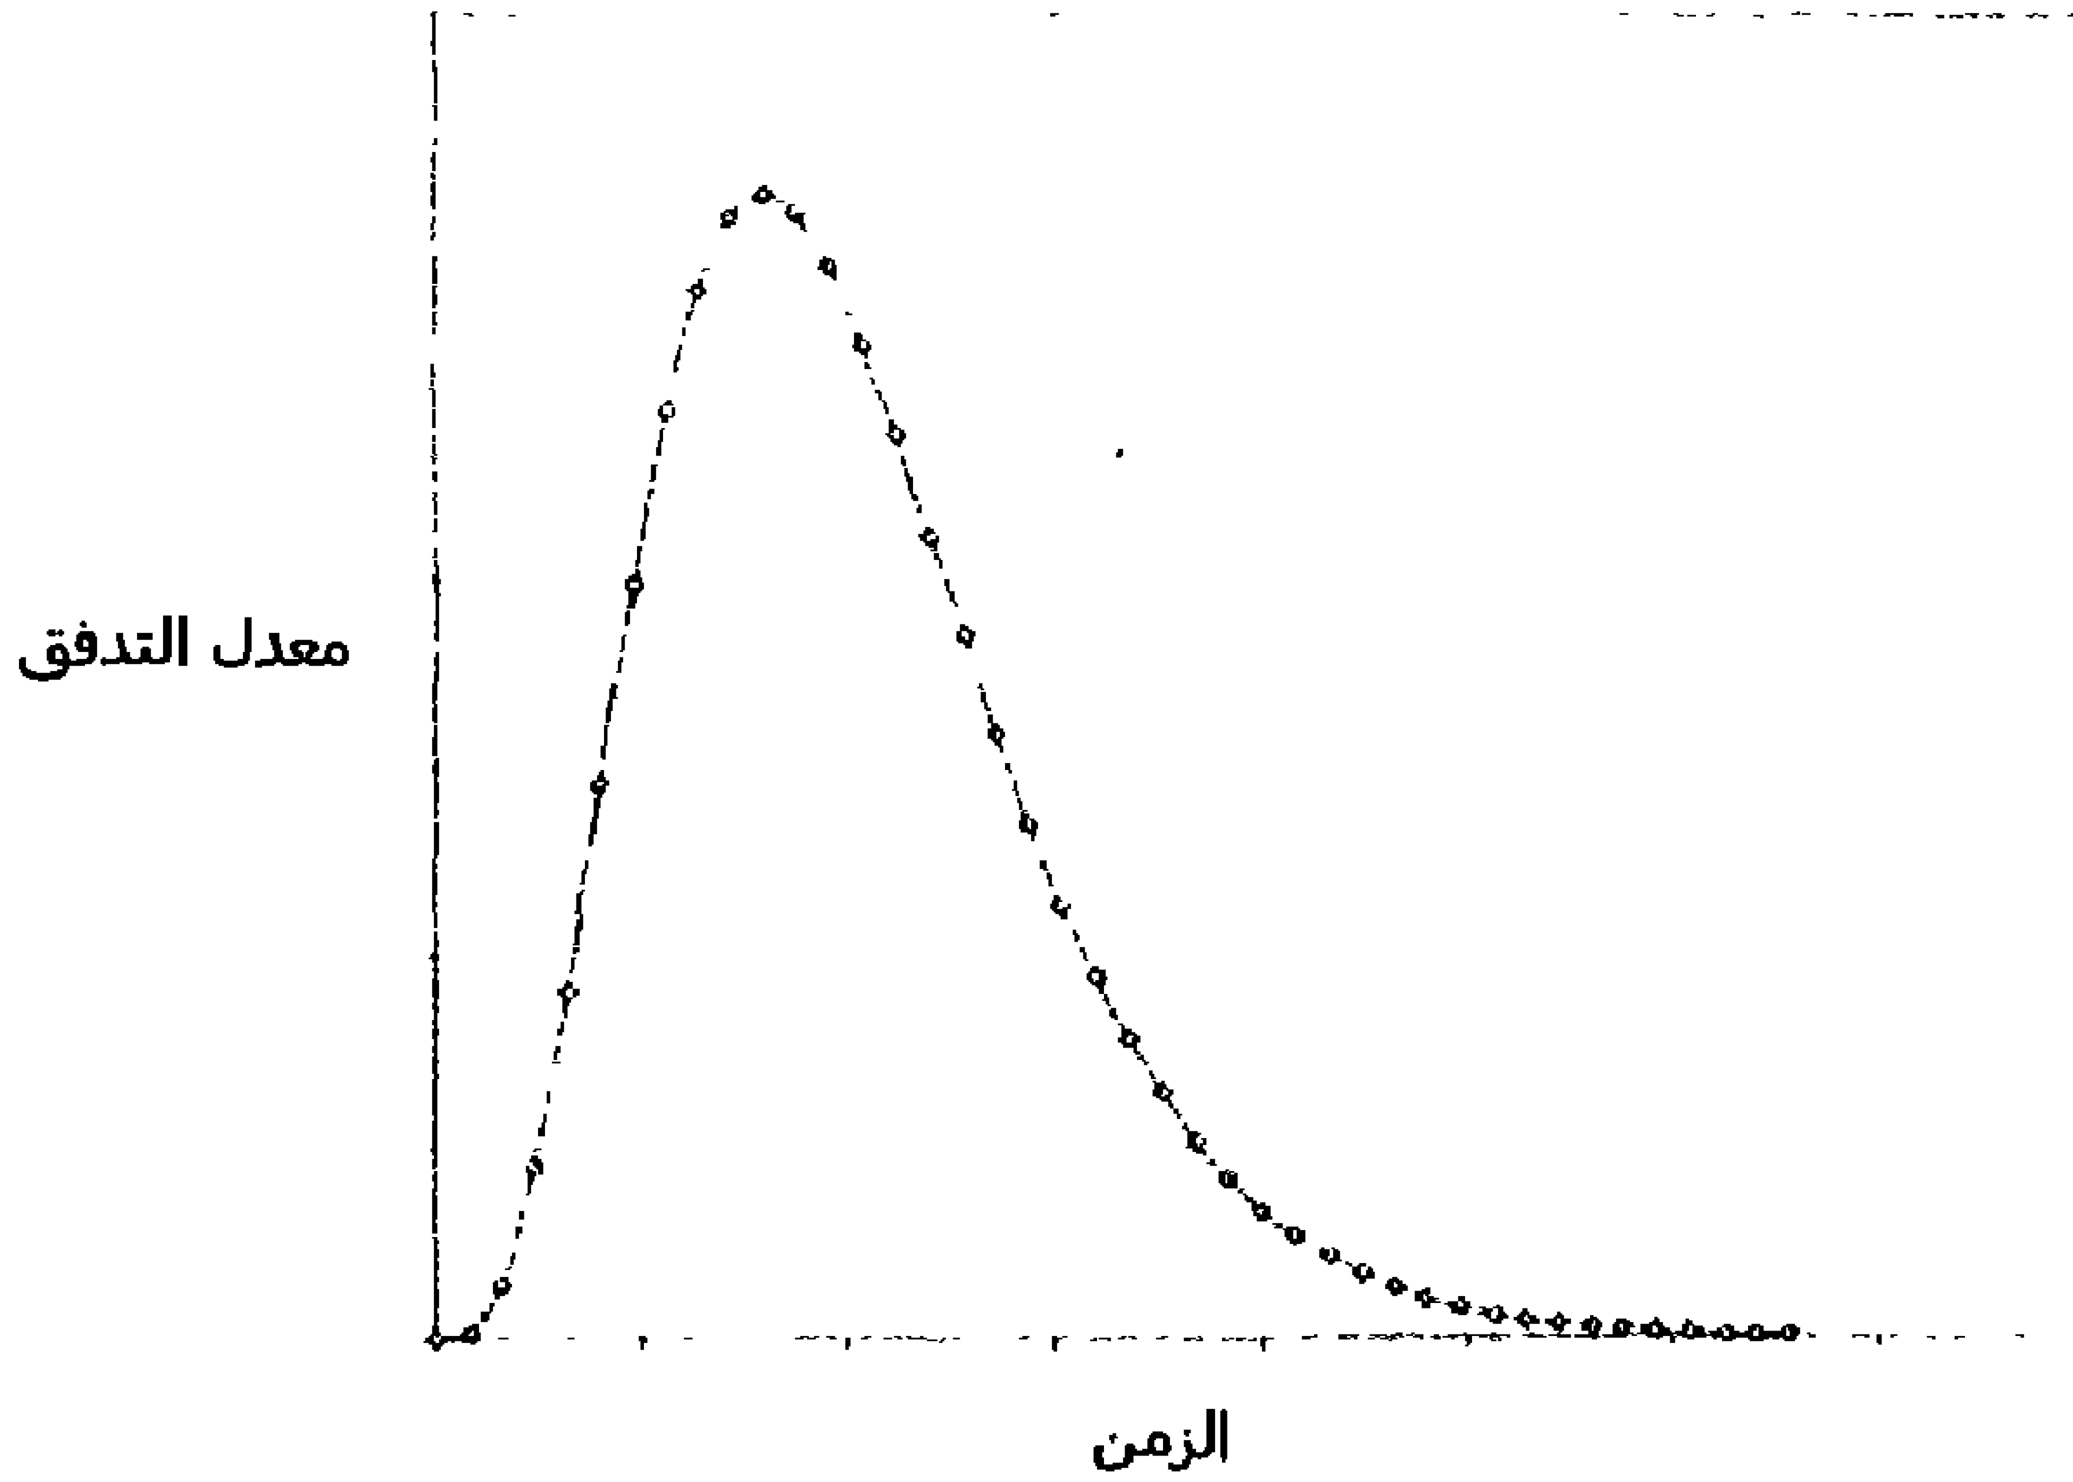
المخطاطات المائية الوَحْديّة

المخطاط المائي الوَحْديّ هو مخطط مائي بياني للجريان السطحي من 1 ملم لزيادة هطول المطر الساقط بمعدل ثابت خلال مدة D، ومُوزع بشكل منتظم على حوض الصرف. أصبحت الطريقة المعتمدة على المخطاط المائي الوَحْديّ أكثر الطرق استخداماً في أحواض الصرف (مناطق التجميع) الريفية من مثيلتها في المدينة. عَرّف العالمان Wisler & Brater (1959) واحدة العاصفة على أنها

"المخطاط المائي لجريان سطحي ناتج عن مطر شديد وقصير نسبياً يسمى بواحدة العاصفة". هذه الطريقة موصفة بشكل عام في مسارد الكتب، وتتضمن النماذج الحسابية التجارية عموماً حزماً حسابية معتمدة على هذه الفلسفة.

يمتلك المخطاط المائي الوَحْديّ عدداً محدوداً من البارامترات (بين 1 ولا أكثر من 3 إلى 4)، التي تشمل على المعلومات الهيدروليكية والهيدرولوجية لمنطقة التجميع. إن المتغيرات الهندسية الصرفة - مثل المساحة - تكون مقبولة عموماً بشكل غير قابل للشك، في حين يجب أن تُحسب وتُخمن البارامترات البقية. إن أي شخص يتعامل مع البارامترات يدرك درجة الشك التي تظهر عند وضعها.

الشكل (1) *معدل التدفق من 1 مم لهطول المطر في مخطاط مائي وَحْديّ.*



ربما لا يكون في طبيعة المخطاطات المائية الوَحْديّة نية إعطاء المعنى الفيزيائي للبارامترات، على الرغم من أنه لكي يتم تقييمها، يكون ضرورياً في الحقيقة اللجوء إلى علاقتها بالمتغيرات الهندسية والهيدروليكية. كما أنه ليس من الشائع لبارامترات مخطاط مائي وَحْديّ أن يكون مترافقاً بقائمة معقدة من المتغيرات الفيزيائية المكتسبة خلال سلسلة من التجارب، التي تكون مجرد ضبط أو حل لما يُعرف "بالتحليل الخلفي" في الأمْثلة، ويشير إلى النماذج الحسابية المطبقة في نموذج Hydroworks (www.eworksllc.com/hydroworks.asp) من أجل الثابت الزمني K لـ Nash UH، أو الطرق المتضمنة في Viessman et at. (1989). ليس لدى البارامتر المُركب أي معنى فيزيائي ملموس، والعلاقة المكتسبة - التي لا تأتي من تحليل بُعدي - ليست أكثر من ملاءمة

أفضل لمسألة ما، التي لا تبدو بأنها تمتلك حلاً فريداً قابلاً للتطبيق على أي منطقة تجميع بسبب عدد المتغيرات المهدد بالضياع (Vaes, 1999).

المعادلات الهيدروليكية

يوجد أيضاً نماذج تعتمد فقط على إعادة إنتاج موثوق للعمليات الهيدروليكية، التي تحدث بالفعل في منطقة التجميع. وهذه هي النماذج الأكثر استخداماً عموماً، وهي تعتمد على معادلات Saint_Vennant أو على بعض نسخها المُبسطة، وتحديداً تطبيق معادلات الموجة السينمائية أو الصياغات المماثلة، كتلك المستخدمة في الحزمة البرمجية RNNOFF من نموذج SWMM (Huber, 1992) والذي هو بدون أدنى شك الأكثر استخداماً على نحو واسع على المستوى الدولي.

تُشكل منطقة التجميع في هذه الأنواع من النماذج بشكل مثالي في سلسلة من القنوات التي تمثل السقوف وأقسام الشوارع المتصلة مع بعضها البعض. وتملك كل واحدة خصائص هيدروليكية خاصة بها (التخزين المنخفض الابتدائي، معامل الاحتكاك ... الخ) ذات معنى فيزيائي معروف.

تتطلب النمذجة بمعاملات Saint_Vennant من أجل حساب التدفقات المُولّدة بنتيجة هطول الأمطار معرفة جيدة بشبكة التصريف، بالإضافة إلى خصائص فتحة التدفق وطبوغرافية المدينة. إذا كانت منطقة التجميع مبينة بتلك القنوات التي تمتلك خصائص هيدروليكية متجانسة، فإن عملية التفرق ستؤدي إلى التعريف بصرامة لعدد لا نهائي من العناصر الصغيرة، التي يجب أن تُحدد خصائصها بشكل منفرد.

النماذج المعتمدة على بيانات حقيقية

الطريقة الموثوقة المستخدمة بقدر ما كحدود للوسائل والوقت المتاح هي المقارنة ببيانات حقيقية. من الواضح أن هذه ليست أداة صالحة لتطوير التصميم، طالما أن المقارنة تُنفذ أثناء مرحلة التشغيل، غير أنها مفيدة في تحليل كيفية عمل شبكة ما، أو لدراسة اتصالاتها الممكنة ببنى أخرى (خزانات الاحتجاز، خزانات الفيضان، خزانات التدفق الأولي) مع التيار.

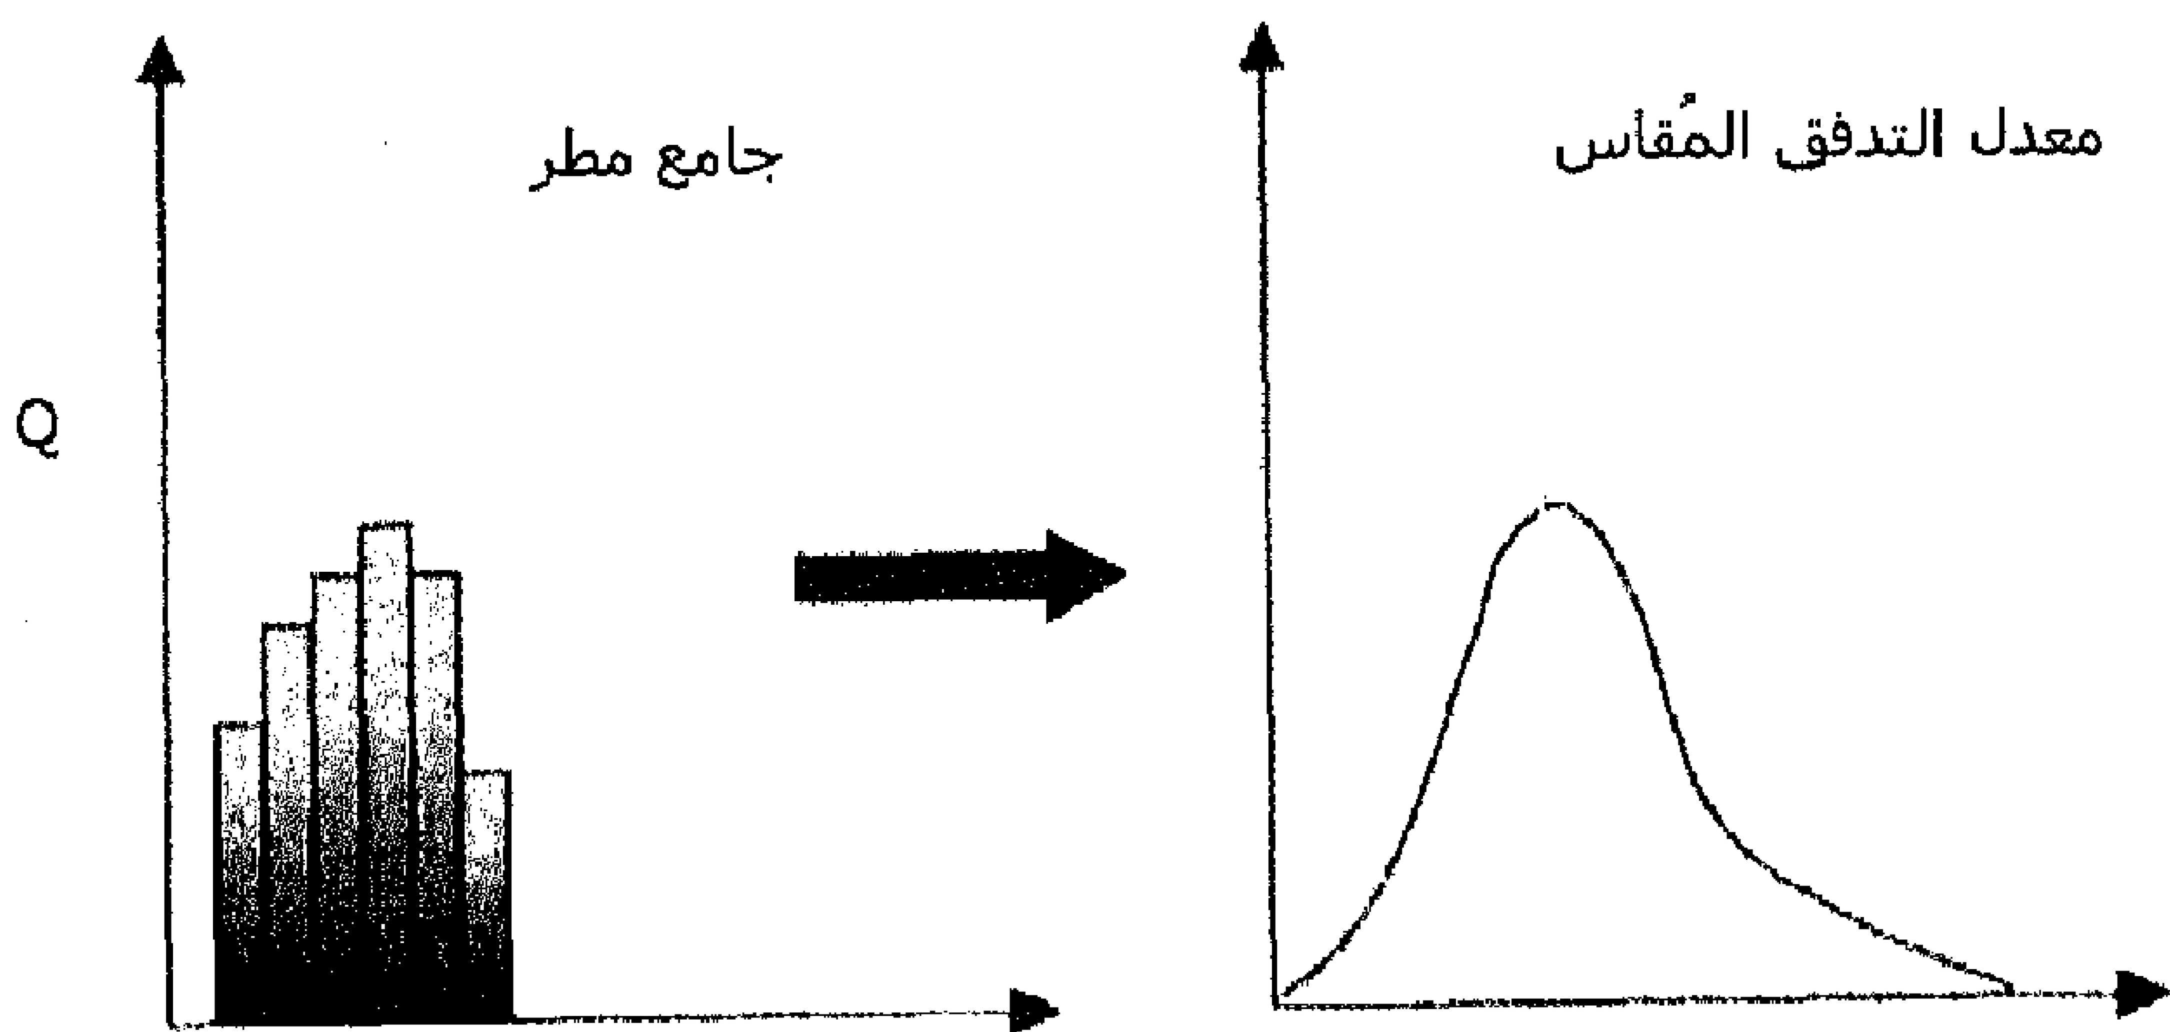
تعتمد المقارنة على تجهيز منطقة التجميع بمقياس مطر واحد أو أكثر وبمقياس تدفق واحد أو عدة مقاييس، والتي يجب أن تُركز في أخفض نقطة من الشبكة، بحيث تتقاطع مع كل المياه. قد يتجاوز المخطاط المائي المُسجل بمقياس التدفق مثيله المَقدم من قبل النموذج الحسابي، بعد أن يكون قد زودَّ التسجيل لهطول المطر. وبمقارنة اثنين منهم، يمكننا تحديد ما إذا النموذج يعيد إنتاج الحالة الحقيقية بطريقة موثوقة كفاية من عدمه، والدرجة التي تكون فيها بعض البارامترات قد انتهت أو تحت التخمين. وبالتالي، إذا لم تتطابق القمم المُسجلة والقياسات زمنياً، فيجب أن

نفترض بأن البارامترات، والتي تستلزم التأخير، لم تُخمن بشكل صحيح. وإذا لم يتطابق الحجم الابتدائي والنهائي، فسوف تكمن المشكلة في البارامترات التي تتعامل مع التسرب والاحتجاز أيضاً ... وهلم جراً. بالنسبة لبيانات حدوث هطول المطر (التساقط والتدفق) يكون من البساطة جداً تعديل البارامترات، بحيث تمتلك المخططات المائية المُقاسة والمحسوبة مظهراً مماثلاً. على أية حال، لا يضمن ذلك بأن هذه البارامترَات المُصححة ستعطي نتيجة صحيحة في حدث آخر. إذا نُفذَ نفس التمرين على سلسلة متوالية من هطولات الأمطار، فسيكون منطقياً افتراض أن النتيجة تمثل مجموعة نهائية من البارامترات المتوسطة مع قدرة على التنبؤ، حتى بالرغم من أن التوافق لكل هطول مطري محدد، لن يكون جيداً مثل التوافق الذي سُيحصل عليه، فيما إذا تم تطبيقه فقط على هذا الحدث.

النمذجة

المسألة هي توقع التدفق لحوض صرف مدينة مثالي من حساس المطر المُجمع المتوضع في مجرور المدينة. والهدف هو توقع معدل التدفق الناتج من المطر. عادةً، تمتلك هاتان الإشارتان (هطول المطر والتدفق الناجم عن المطر) علاقة، تظهر في إشارة أخرى تدّور إشارة مقياس المطر إلى ذلك التدفق (الشكل 2). لدى هذه الإشارات شكل التوابع الأسية المتناقصة، التي تعمل كاستجابة لتحفيز نظام يتصل بكلتا الإشارتين.

الشكل (2) *حساس جامع المطر وحساس معدل التدفق.*

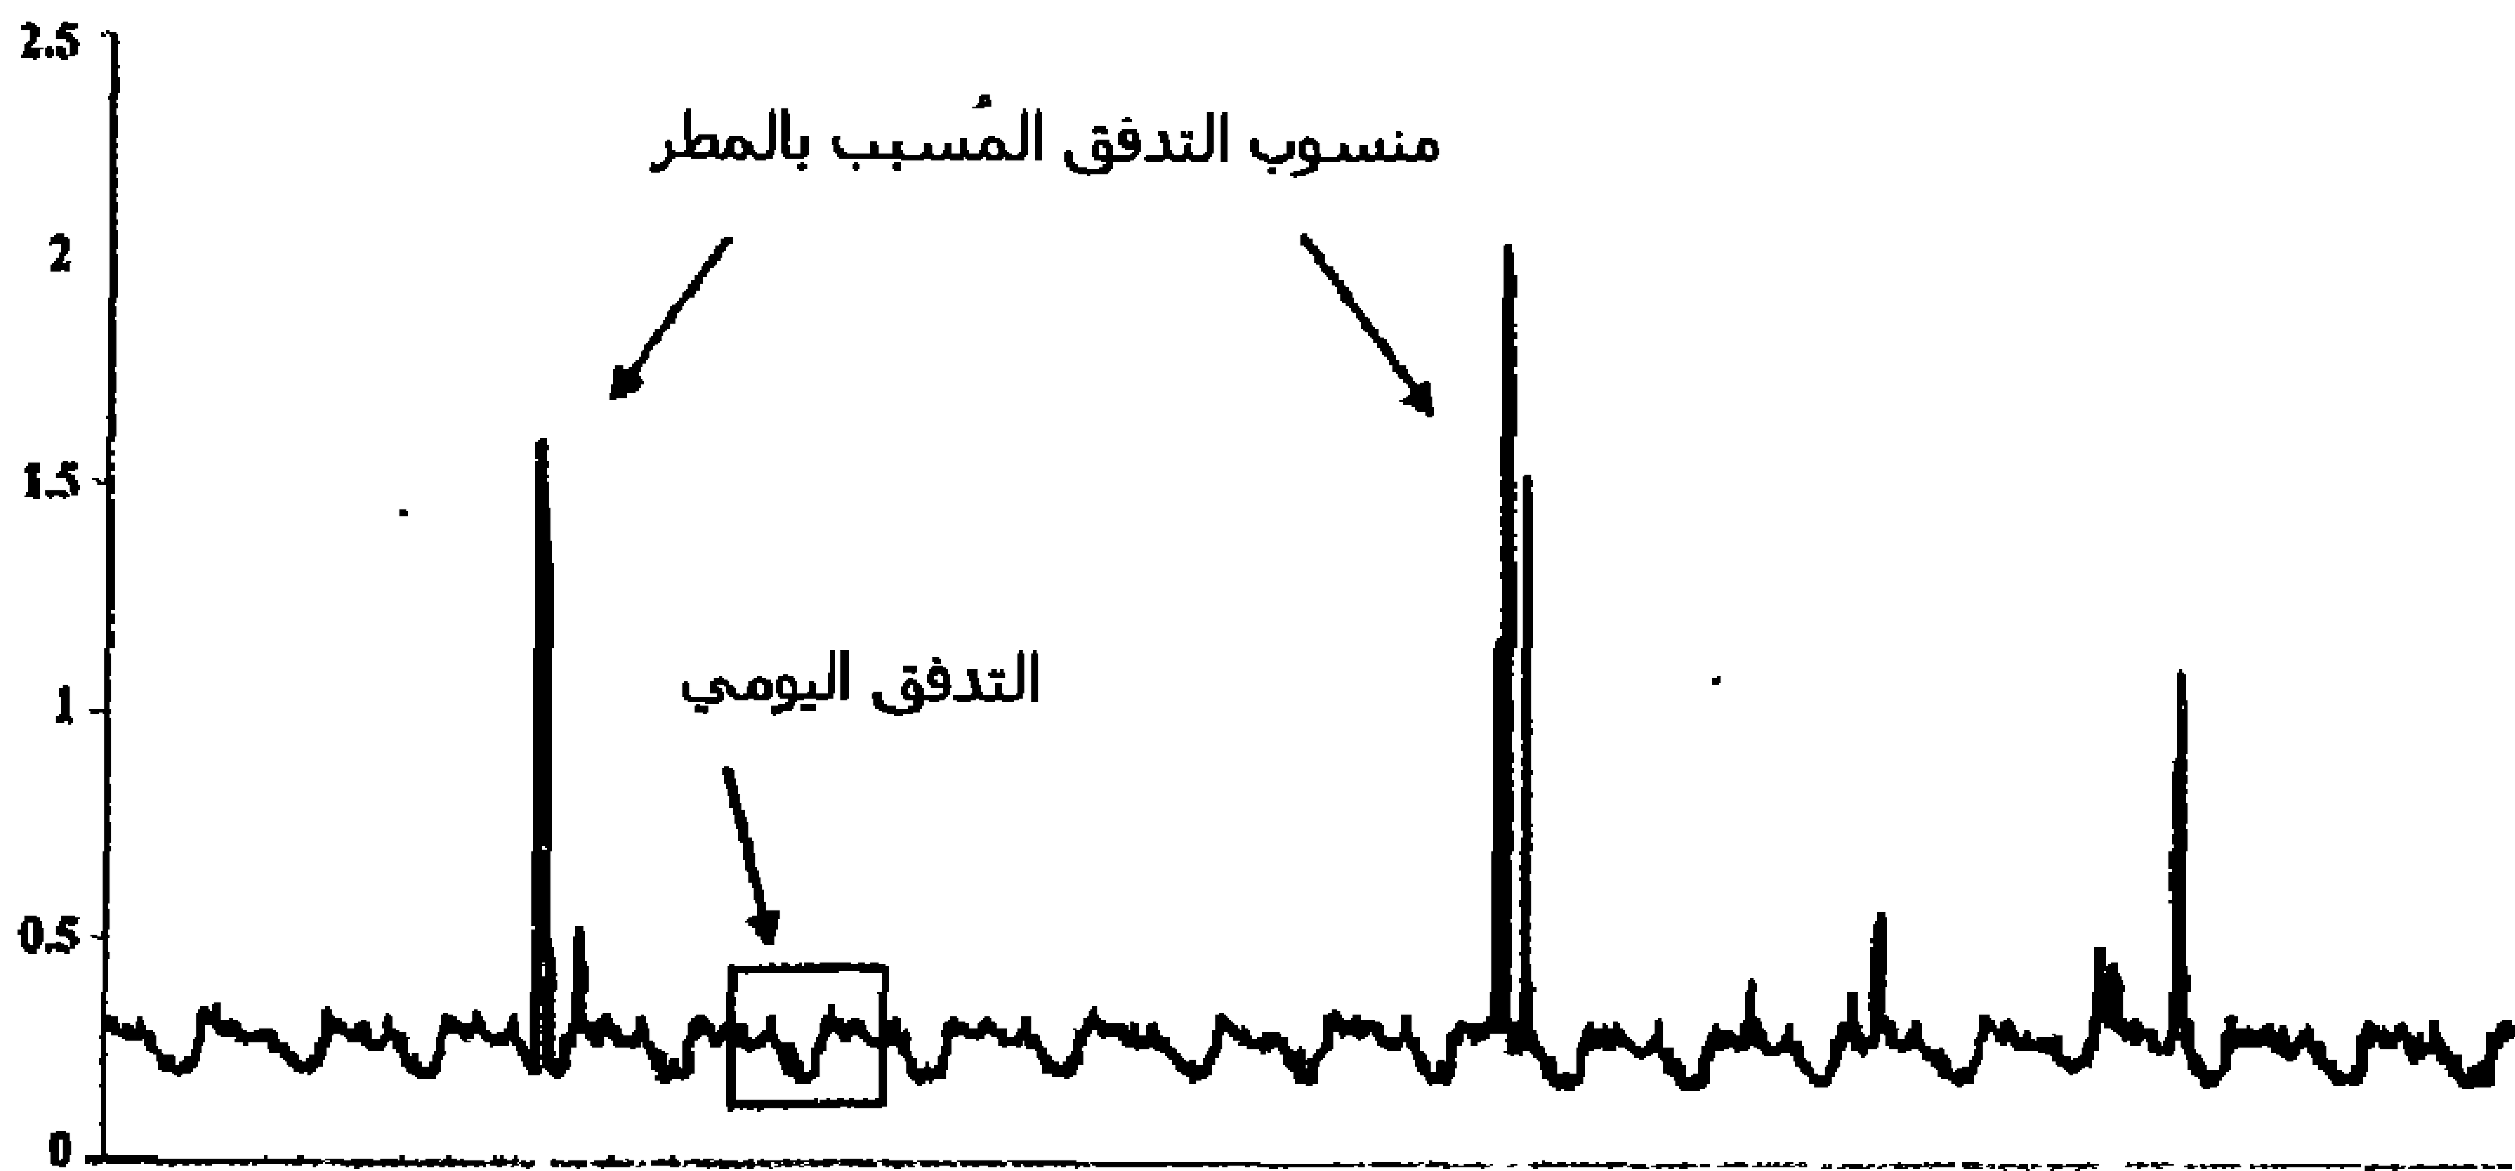


تمتلك إشارة منسوب التدفق حالتين مختلفتين. بحيث يمكن تحليلها إلى إشارتين مركبتين لها، تمثل أحداهما النمط اليومي لاستخدام الماء من قبل سكان المدينة، والأخرى ناتجة عن هطول المطر (الشكل 3). وبالتالي، يمكن تقسيم النظام إلى قسمين:

- نمذجة معدل التدفق اليومي.
- توقع منسوب التدفق المُسبب بالمطر.

يعتمد السلوك التذبذبي لإشارة منسوب التدفق الدورية (تدفق يومي) على كمية الماء المستهلكة من قبل سكان المدينة. على سبيل المثال، يكون الحجم أقل ليلاً، ويزداد خلال النهار مع بعض ساعات الذروة. يُضاف الجريان السطحي المُسبب بهطول مطر متقطع. تتم عادةً دراسة كلا التدفقين بشكل منفصل، طالما أن أصلهما مختلف، وهذه هي المنهجية المستخدمة في الدراسة الحالية.

الشكل (3) *إشارة معدل التدفق اليومي ومنسوب التدفق المُسبب بالمطر.*



نمذجة معدل التدفق اليومي بواسطة ANN

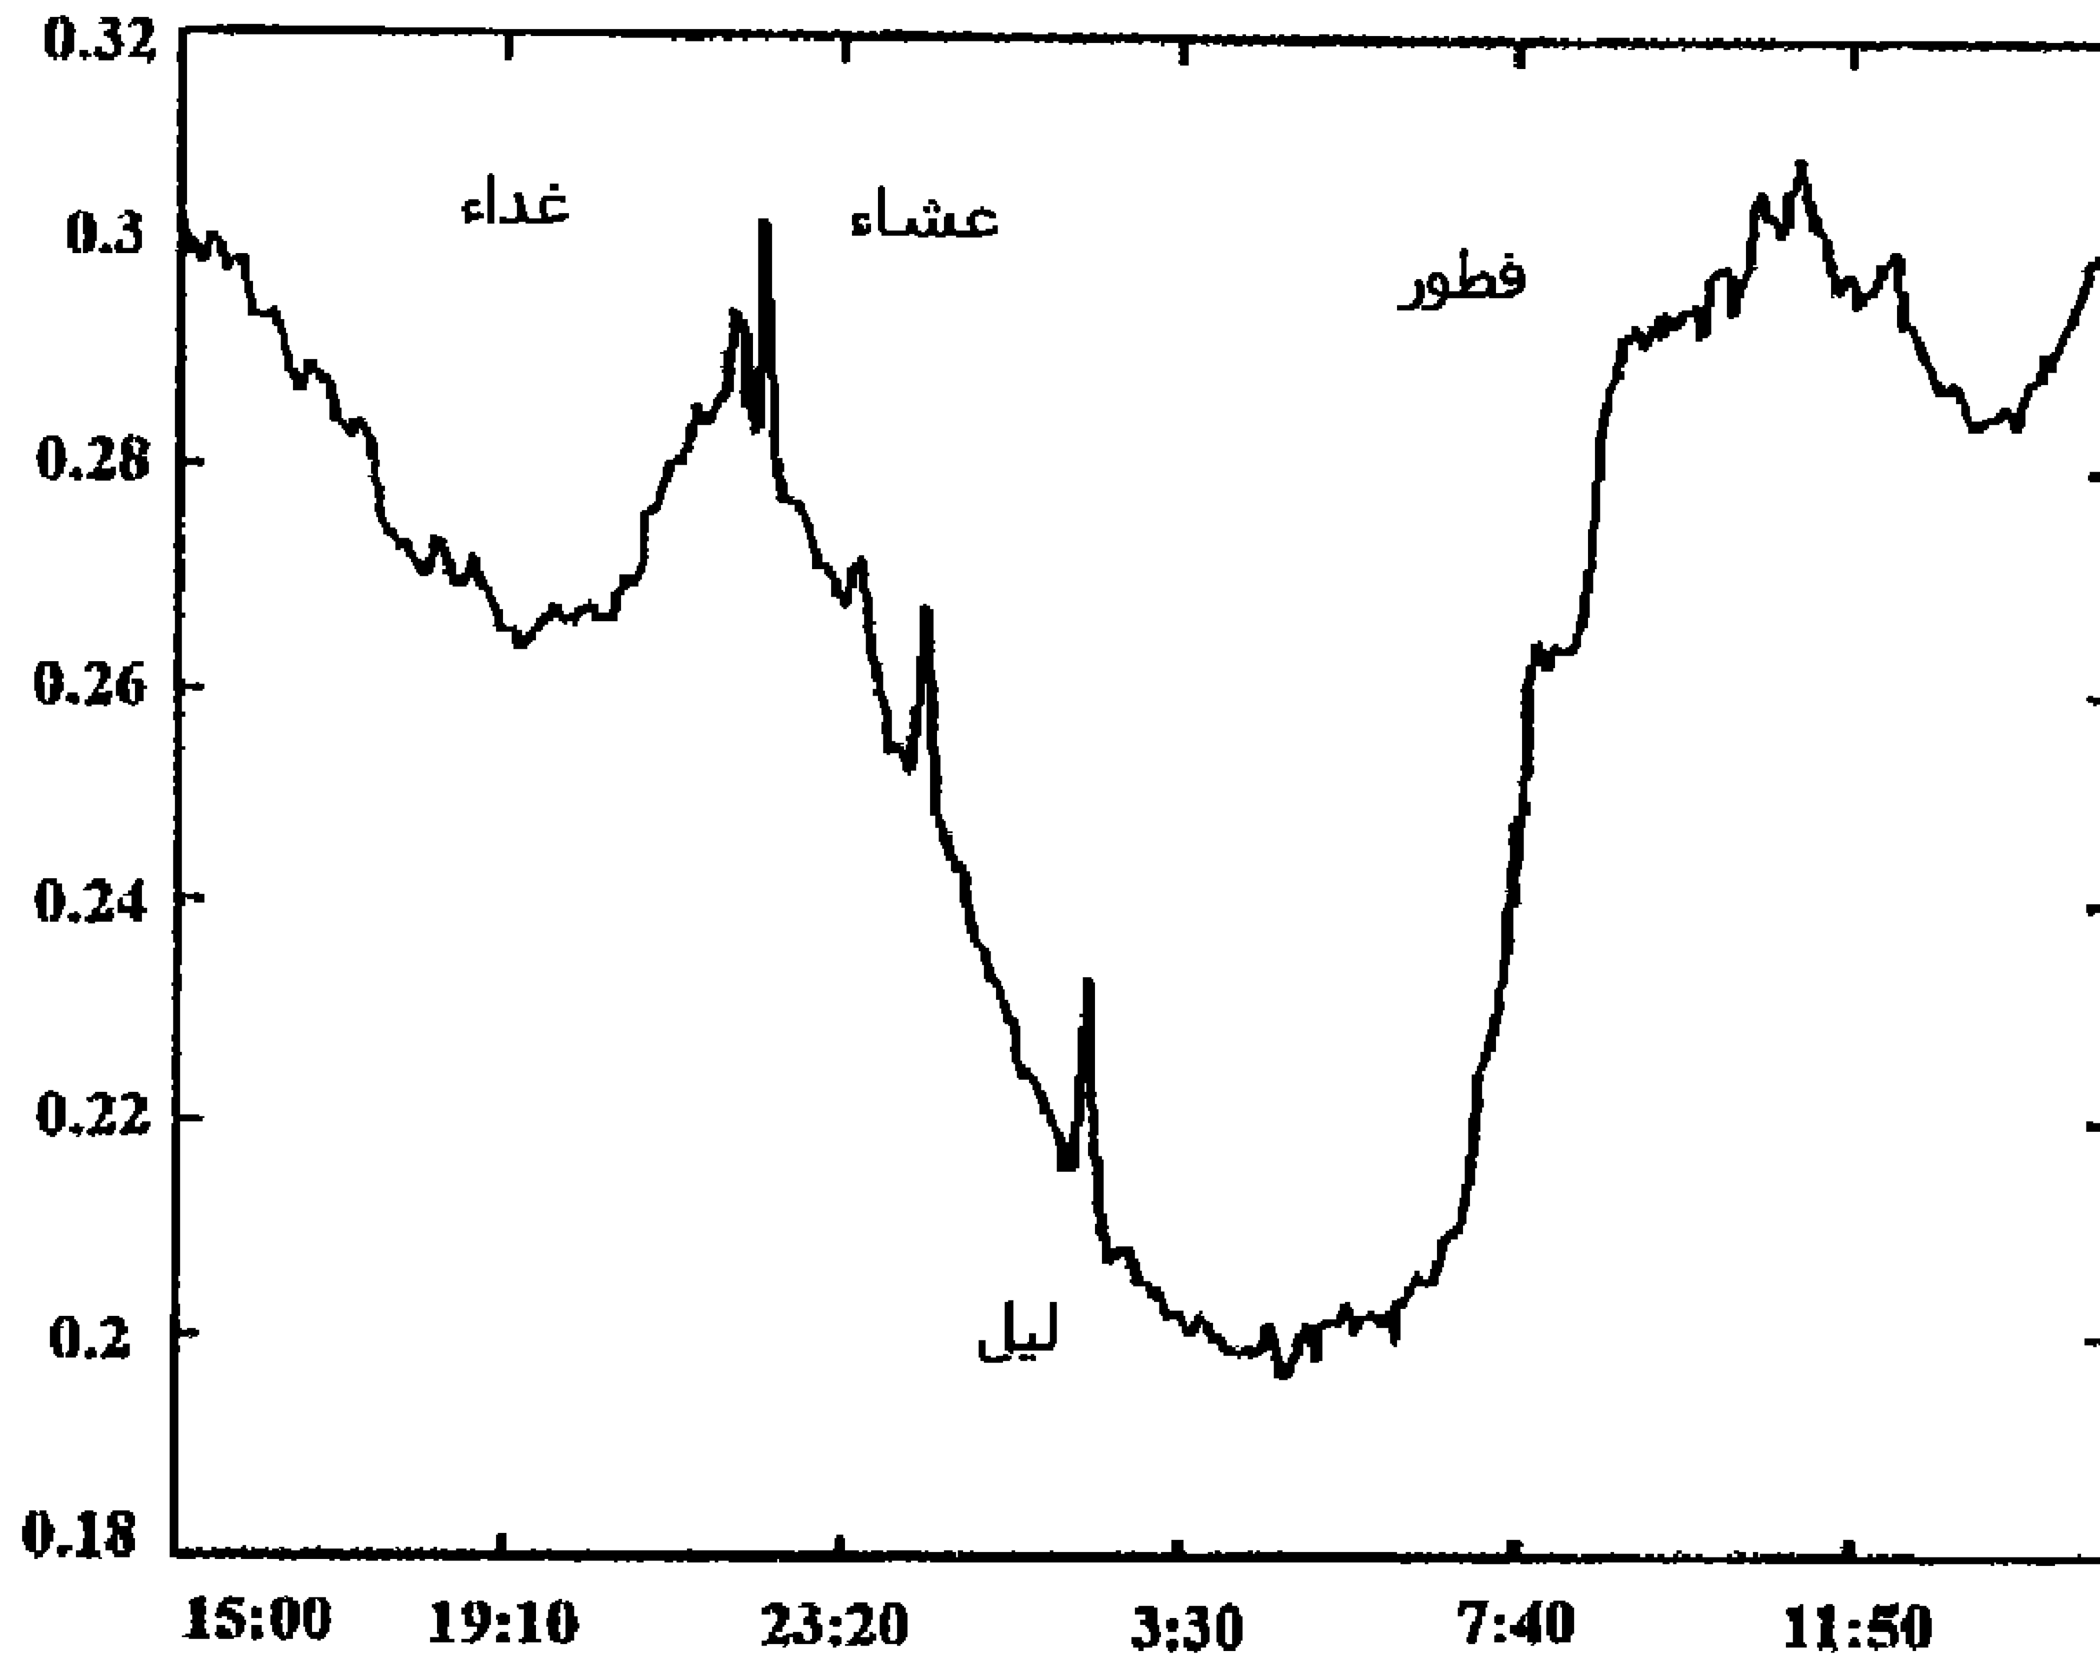
في مجال الهيدرولوجي (علم المياه)، على الرغم من النجاح في نتائج ANN التي تم الحصول عليها (Govindaraju & Rao, 2000)، فإن العاملين في هذا المجال يفضلون استخدام تقانات مثبتة بدلاً من نماذج جديدة ذات تاريخ هيدرولوجي قصير. كما ساهمت طبيعة الصندوق الأسود لـــ ANNs في التردد باستخدام تلك الأدوات على الرغم من وجود تقنيات، يمكنها أن تساعد في تفسير النموذج (Rabuñal, 2004).

يمكن أن نحصل على إشارة تمثيلية للتدفق الوسطي في اليوم بأخذ تلك العينات، التي لم يُؤثر عليها بإشارة المطر فقط، وإيجاد القيمة الوسطية للعينات الموافقة لكل لحظة في اليوم.

بفرض أنه تم أخذ العينات كل 5 دقائق، فإن عدد العينات في اليوم هو 288. وبالتالي، ستملك هذه الإشارة ذلك الطول – كما هو مبين في (الشكل 4) – حيث يوافق المنبسط المركزي ساعات الليل. كما يمكن أيضاً ملاحظة الذرى الموافقة للاغتسال الصباحي (حوالي الساعة

10.00)، والغداء (الساعة 15:00)، والعشاء (حوالي الساعة 22:00). توافق النقطة الأولى الساعة 15:00 (وقت الغداء). وحدة قياس المطر المُجمع بواسطة مقياس المطر هي الميللي متر (مم)، أو الليتر كل متر مربع (ل/م^2).

الشكل (4) *التدفق اليومي الوسطي.*

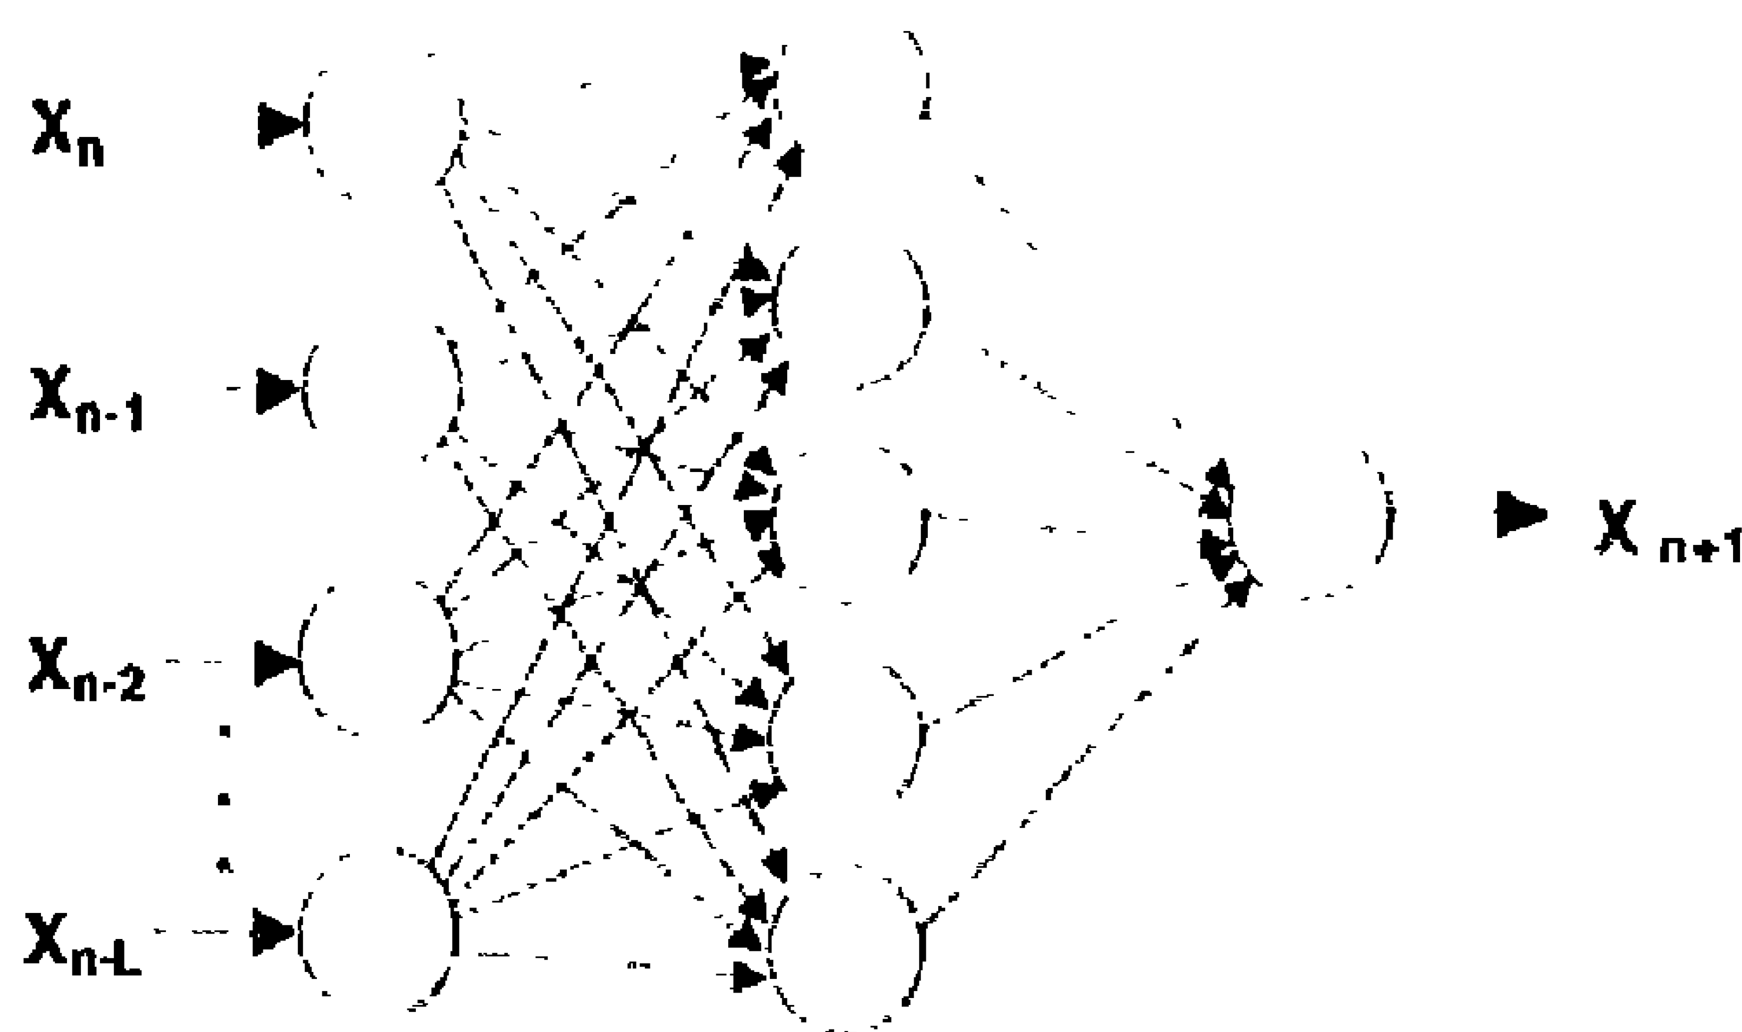


الآن، يمكننا استخلاص هذه الإشارة من إشارة الجريان السطحي الكاملة، بحيث تكون الإشارة ناتجة عن المطر فقط. عندما تكون الإشارة المُستخلصة عبارة عن قيمة متوسطة لإشارة التدفق اليومي، فسيوجد خطأ صغير في الإشارة الناتجة. يترافق نوع آخر من الخصائص مع العينات المتأثرة بالمطر، لأن التدفق الناتج عن المطر والتدفق الناجم عن النشاط البشري ليسا مستقلين. يؤثر الطقس (المطر في هذه الحالة) على سلوك مواطني المدينة (على سبيل المثال، يميل الناس للبقاء في البيت). وبالتالي، لا يمكننا استخلاص القيمة الحقيقية للتدفق الناجم عن النشاط البشري من التدفق الكامل في العينات المتأثرة بالمطر. ولكن يمكننا فقط استخلاص التدفق اليومي في ظروف طبيعية، وبالتالي سيكون هناك خطأً صغيراً. سيتم تصحيح هذه الأخطاء باستخدام ANN. نستخدم ANN أمامية الانتشار بنافذة مؤقتة ذات طول L كدخل وبخرج واحد: العينة التالية هي للنافذة، كما يظهر في (الشكل 5).

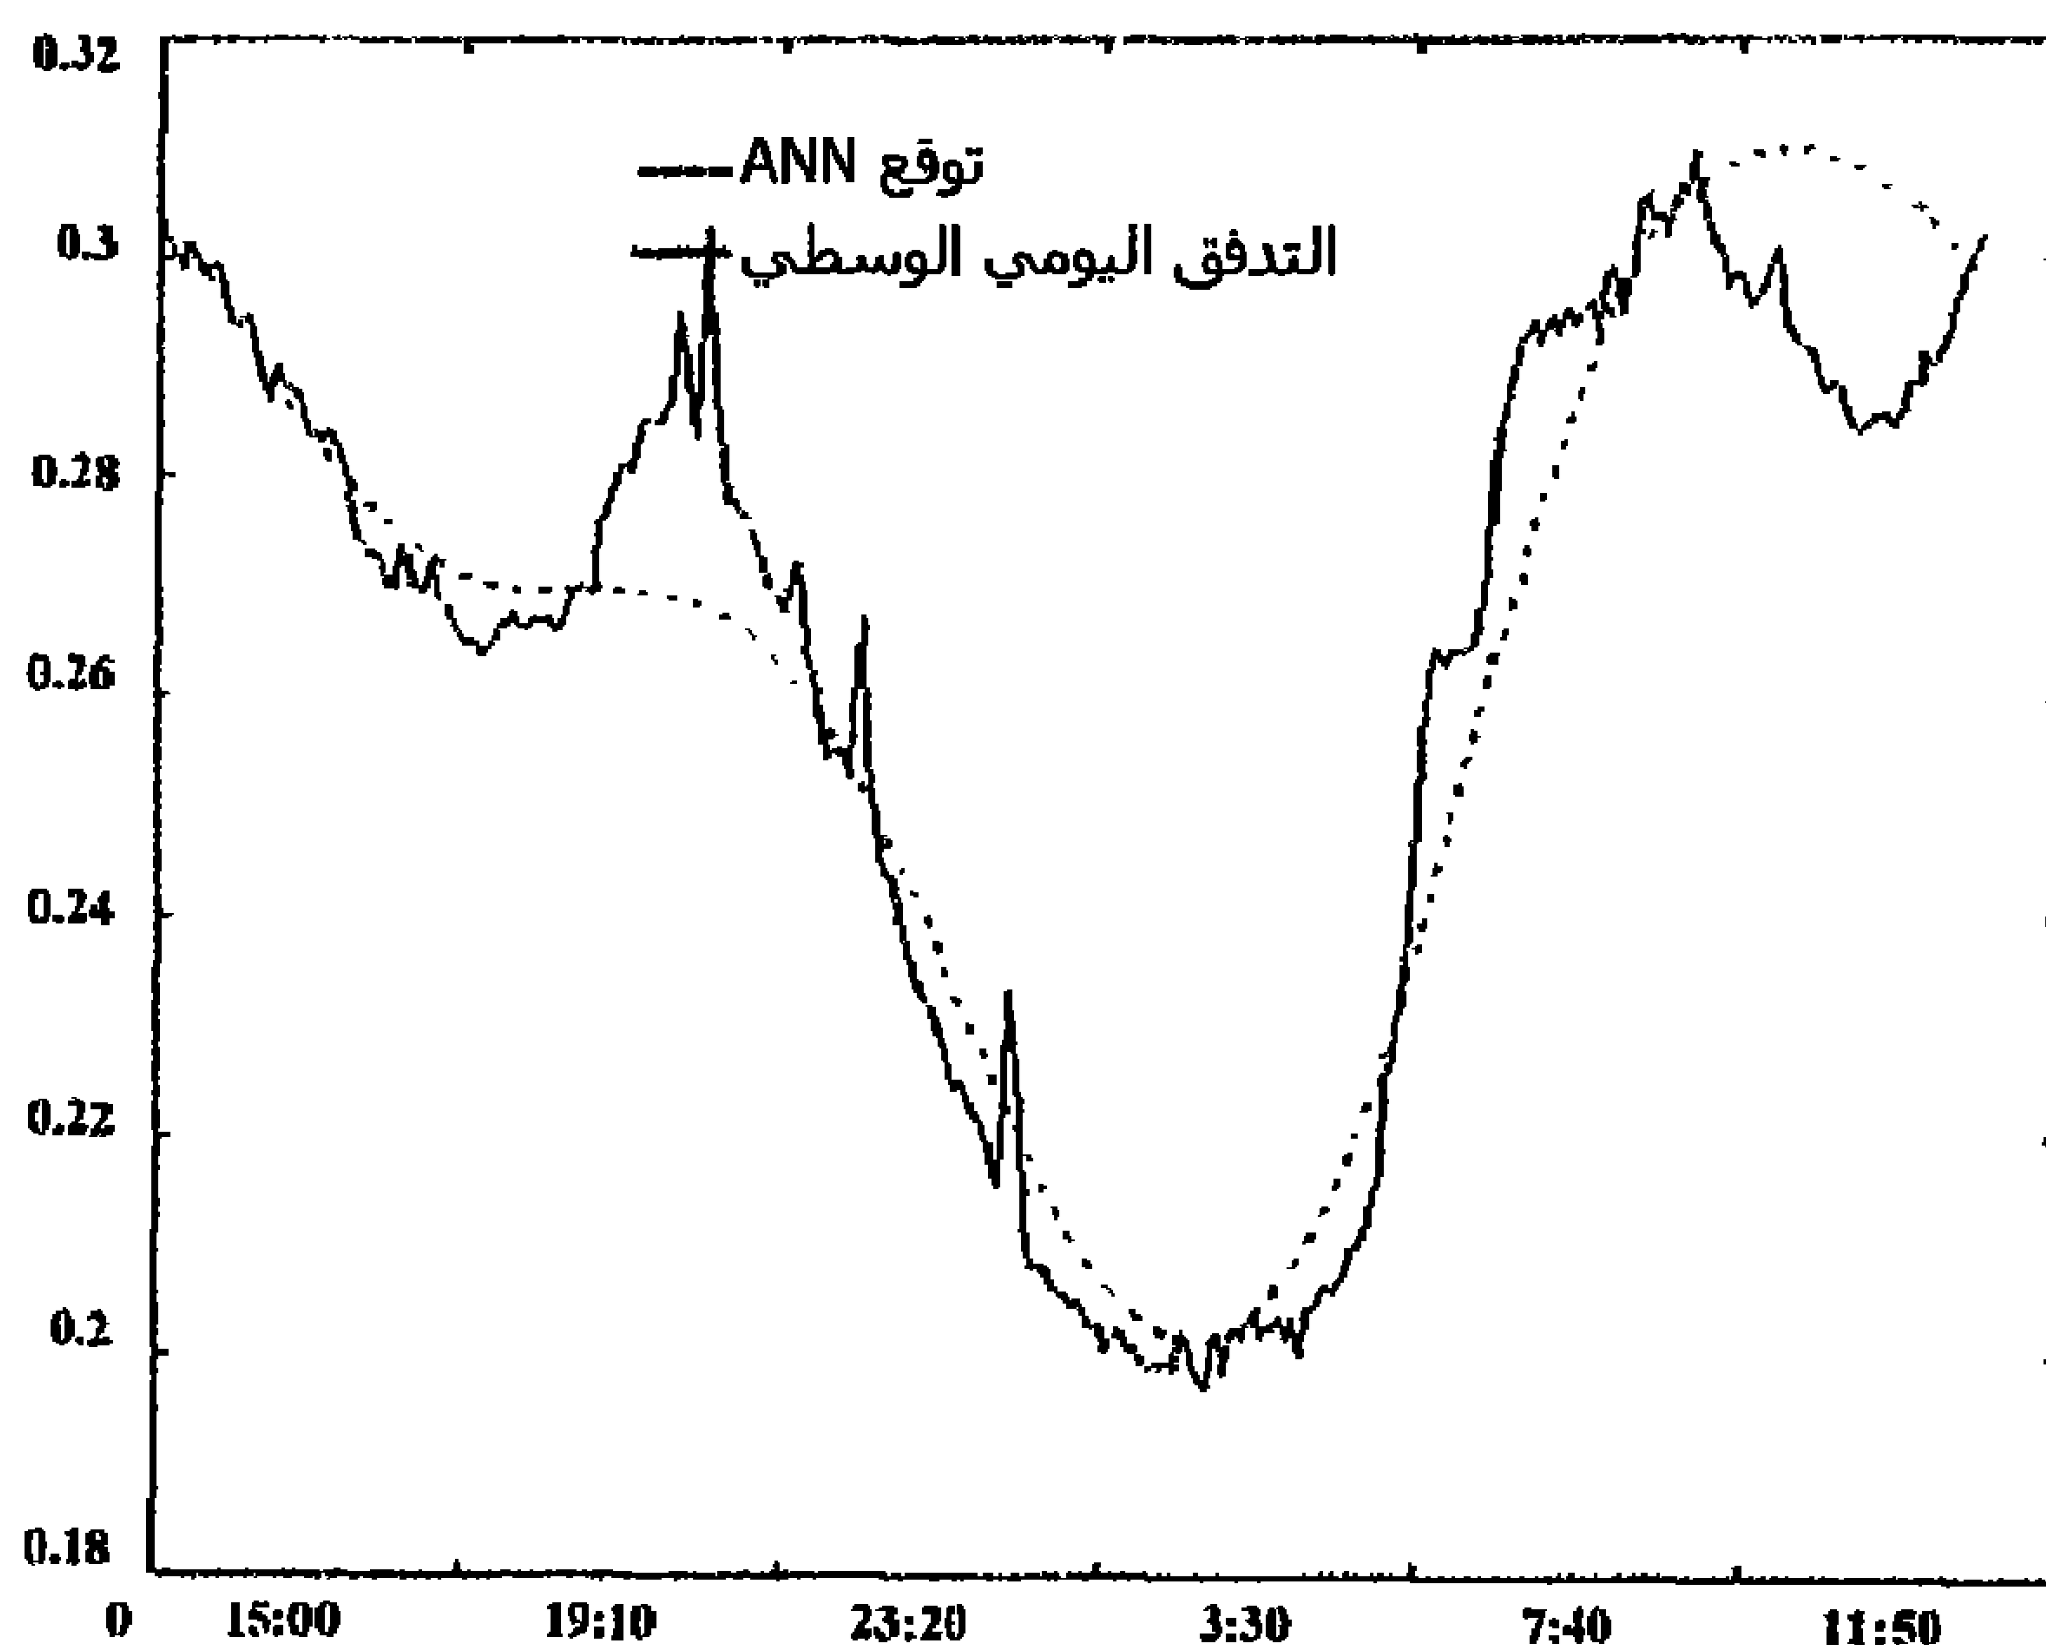
تستخدم غالبية أساليب ANN لمسألة التوقع شبكة متعددة الطبقات مدربة بخوارزمية الانتشار الخلفي (Atiya et at., 1999). لنفرض بأنه لديا سلسلة زمنية x_1 وx_2 وx_n ويُطلب توقع القيمة

x_{n+1}. تُختار المدخلات إلى ANN بشكل نموذجي كالقيم السابقة، أما الناتج فسيكون التوقع. تنفذ معالجة أولية للمدخلات والمخرجات، وهذا يعني استخلاص السمات من المدخلات وتحويل مخرجات الهدف بطريقة، تجعل من الأسهل على الشبكة استخلاص السمات من المدخلات، وتضمها مع المخرجات المطلوبة. البارامترات المستخدمة من أجل ANN وهذه الأحداث موصوفة بالتفصيل في (2003) .Dorado et at. يمكن نمذجة التدفق اليومي دون اعتبار تأثير المطر بـــ ANN بأخذ قيم الدخل بين 0 و287 (كامل اليوم)، وبالمقارنة مع التدفق اليومي الوسطي كما هو ملاحظ في (الشكل 6).

الشكل (5) *البنية الهندسية لـ ANN.*



الشكل (6) *التدفق اليومي الوسطي ونتيجة توقع ANN.*



يجب مُلاحظة أنه لا توجد تعابير تحليلية، تتوقع شكل المنحني اليومي، طالما أنه يعتمد على تنوع من العوامل المرتبطة باستخدام الماء. إن العوامل العديدة غير المُقاسة، التي يمكن أن تقود سلوك هذه الإشارة هي: النشاط الصناعي أو التجاري في المنطقة، نوع الإقامة، هل هي دائمة أم في نهاية الأسبوع، العادات الصحية أو الغذائية ... وهلم جراً. بالتكلم عموماً، هناك منحني مُشكل بمنسوب عالٍ (نهار) وبآخر منخفض (ليل). بهذا الأسلوب، تحقق الطريقة المكتسبة المقاييس الحسابية العاديّة. من الأفضل معالجة ضبط التدفق الوسطي بهدف أخذ نقطة متوسطة بسبب التقلبات المحتملة في تغيير التدفق اعتماداً على الظروف الخارجية، بمعنى حساب معدل تأثير العوامل غير المُقاسة العديدة التي تقود السلوك.

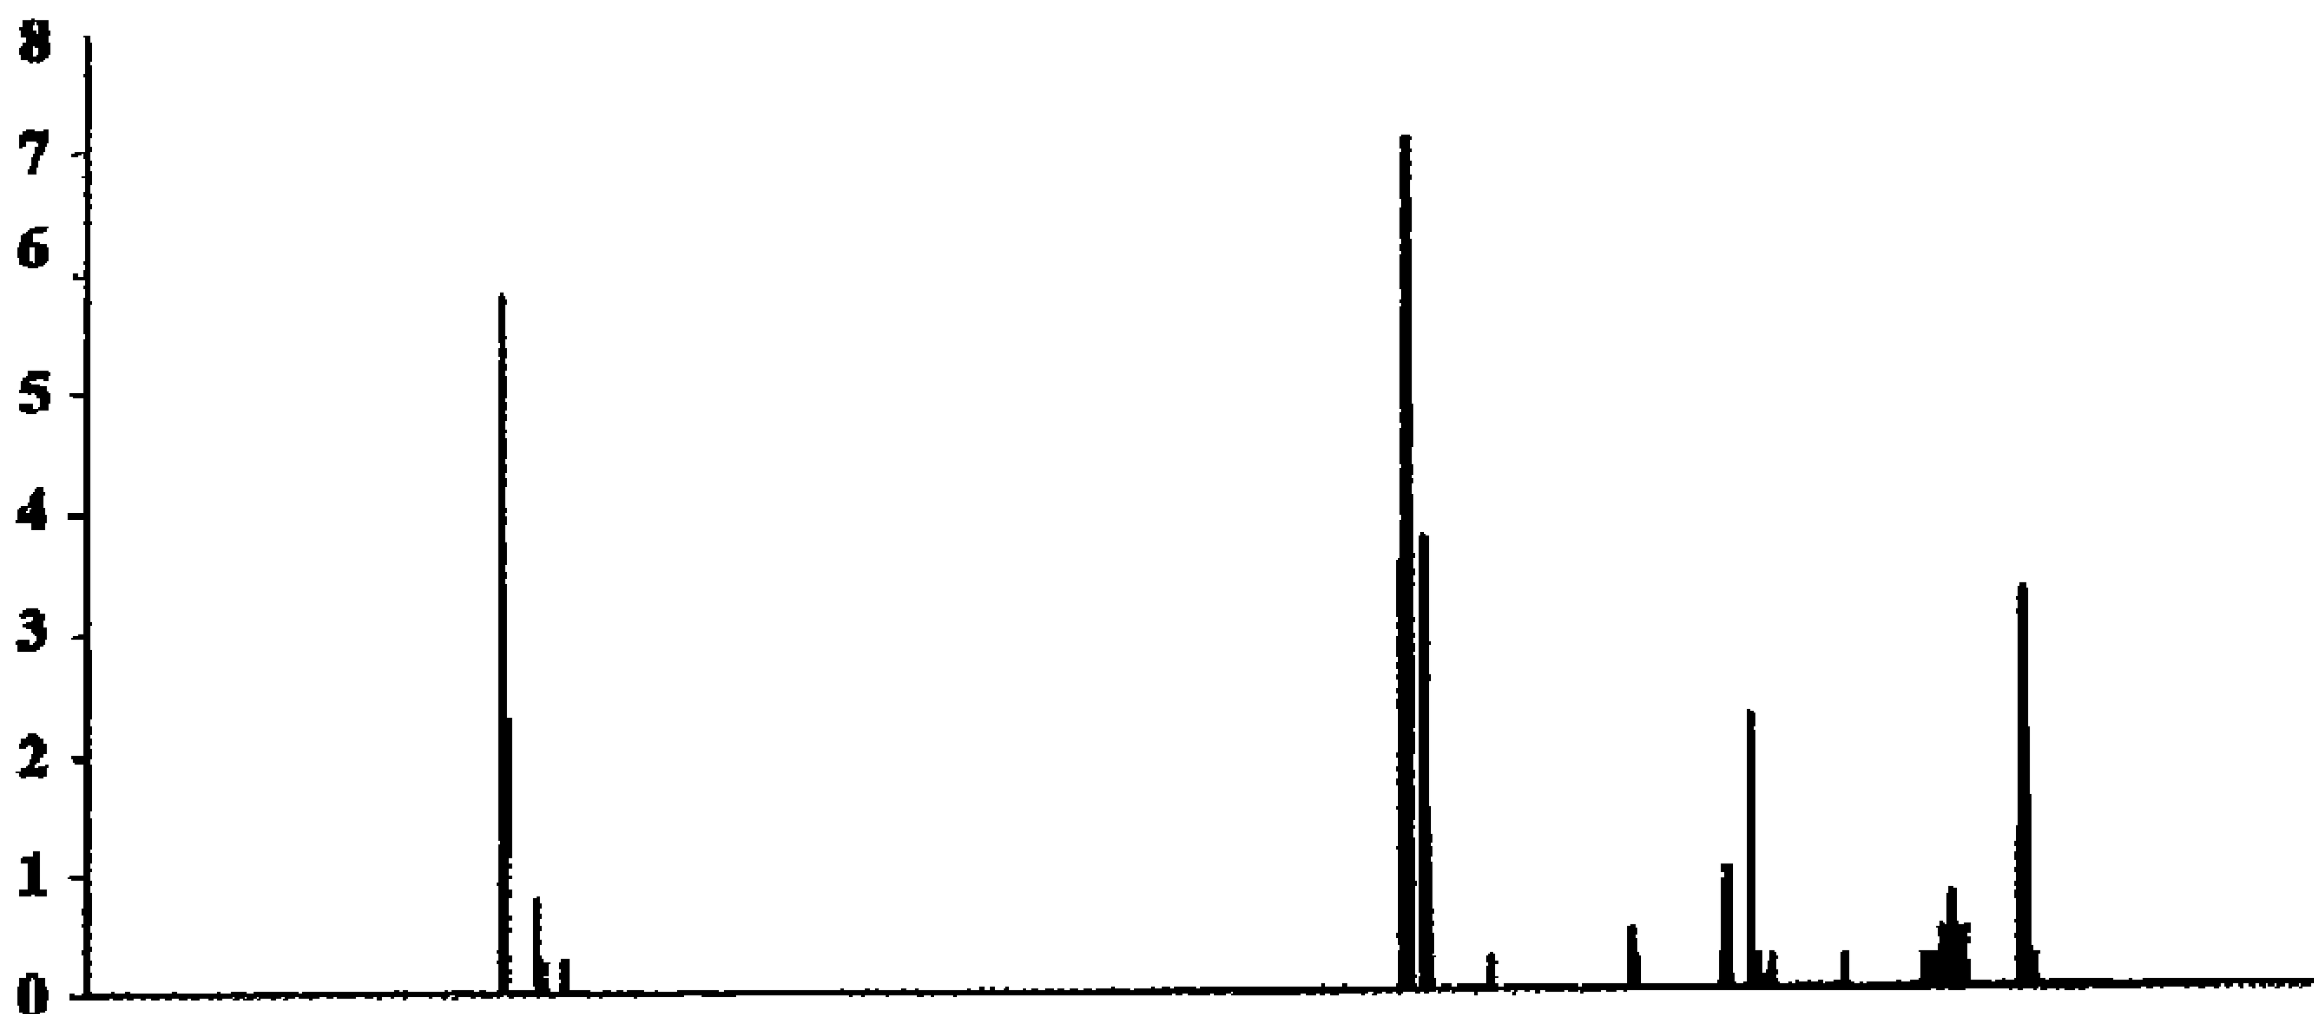
نمذجة تدفق المطر

ما إن يتم نمذجة تأثير معدل التدفق اليومي، حتى تُنفذ معالجة أولية للإشارة الأصلية بغية إزالة هذا المركب اليومي باستخدام الإشارة المنمذجة. ويُنفذ ذلك بواسطة وضع الإشارة المكتسبة فوق إشارة حقيقية وحساب الفرق بينهما. عندها، تكون الإشارة الناتجة ناجمة فقط عن منسوب الهطولات المطرية.

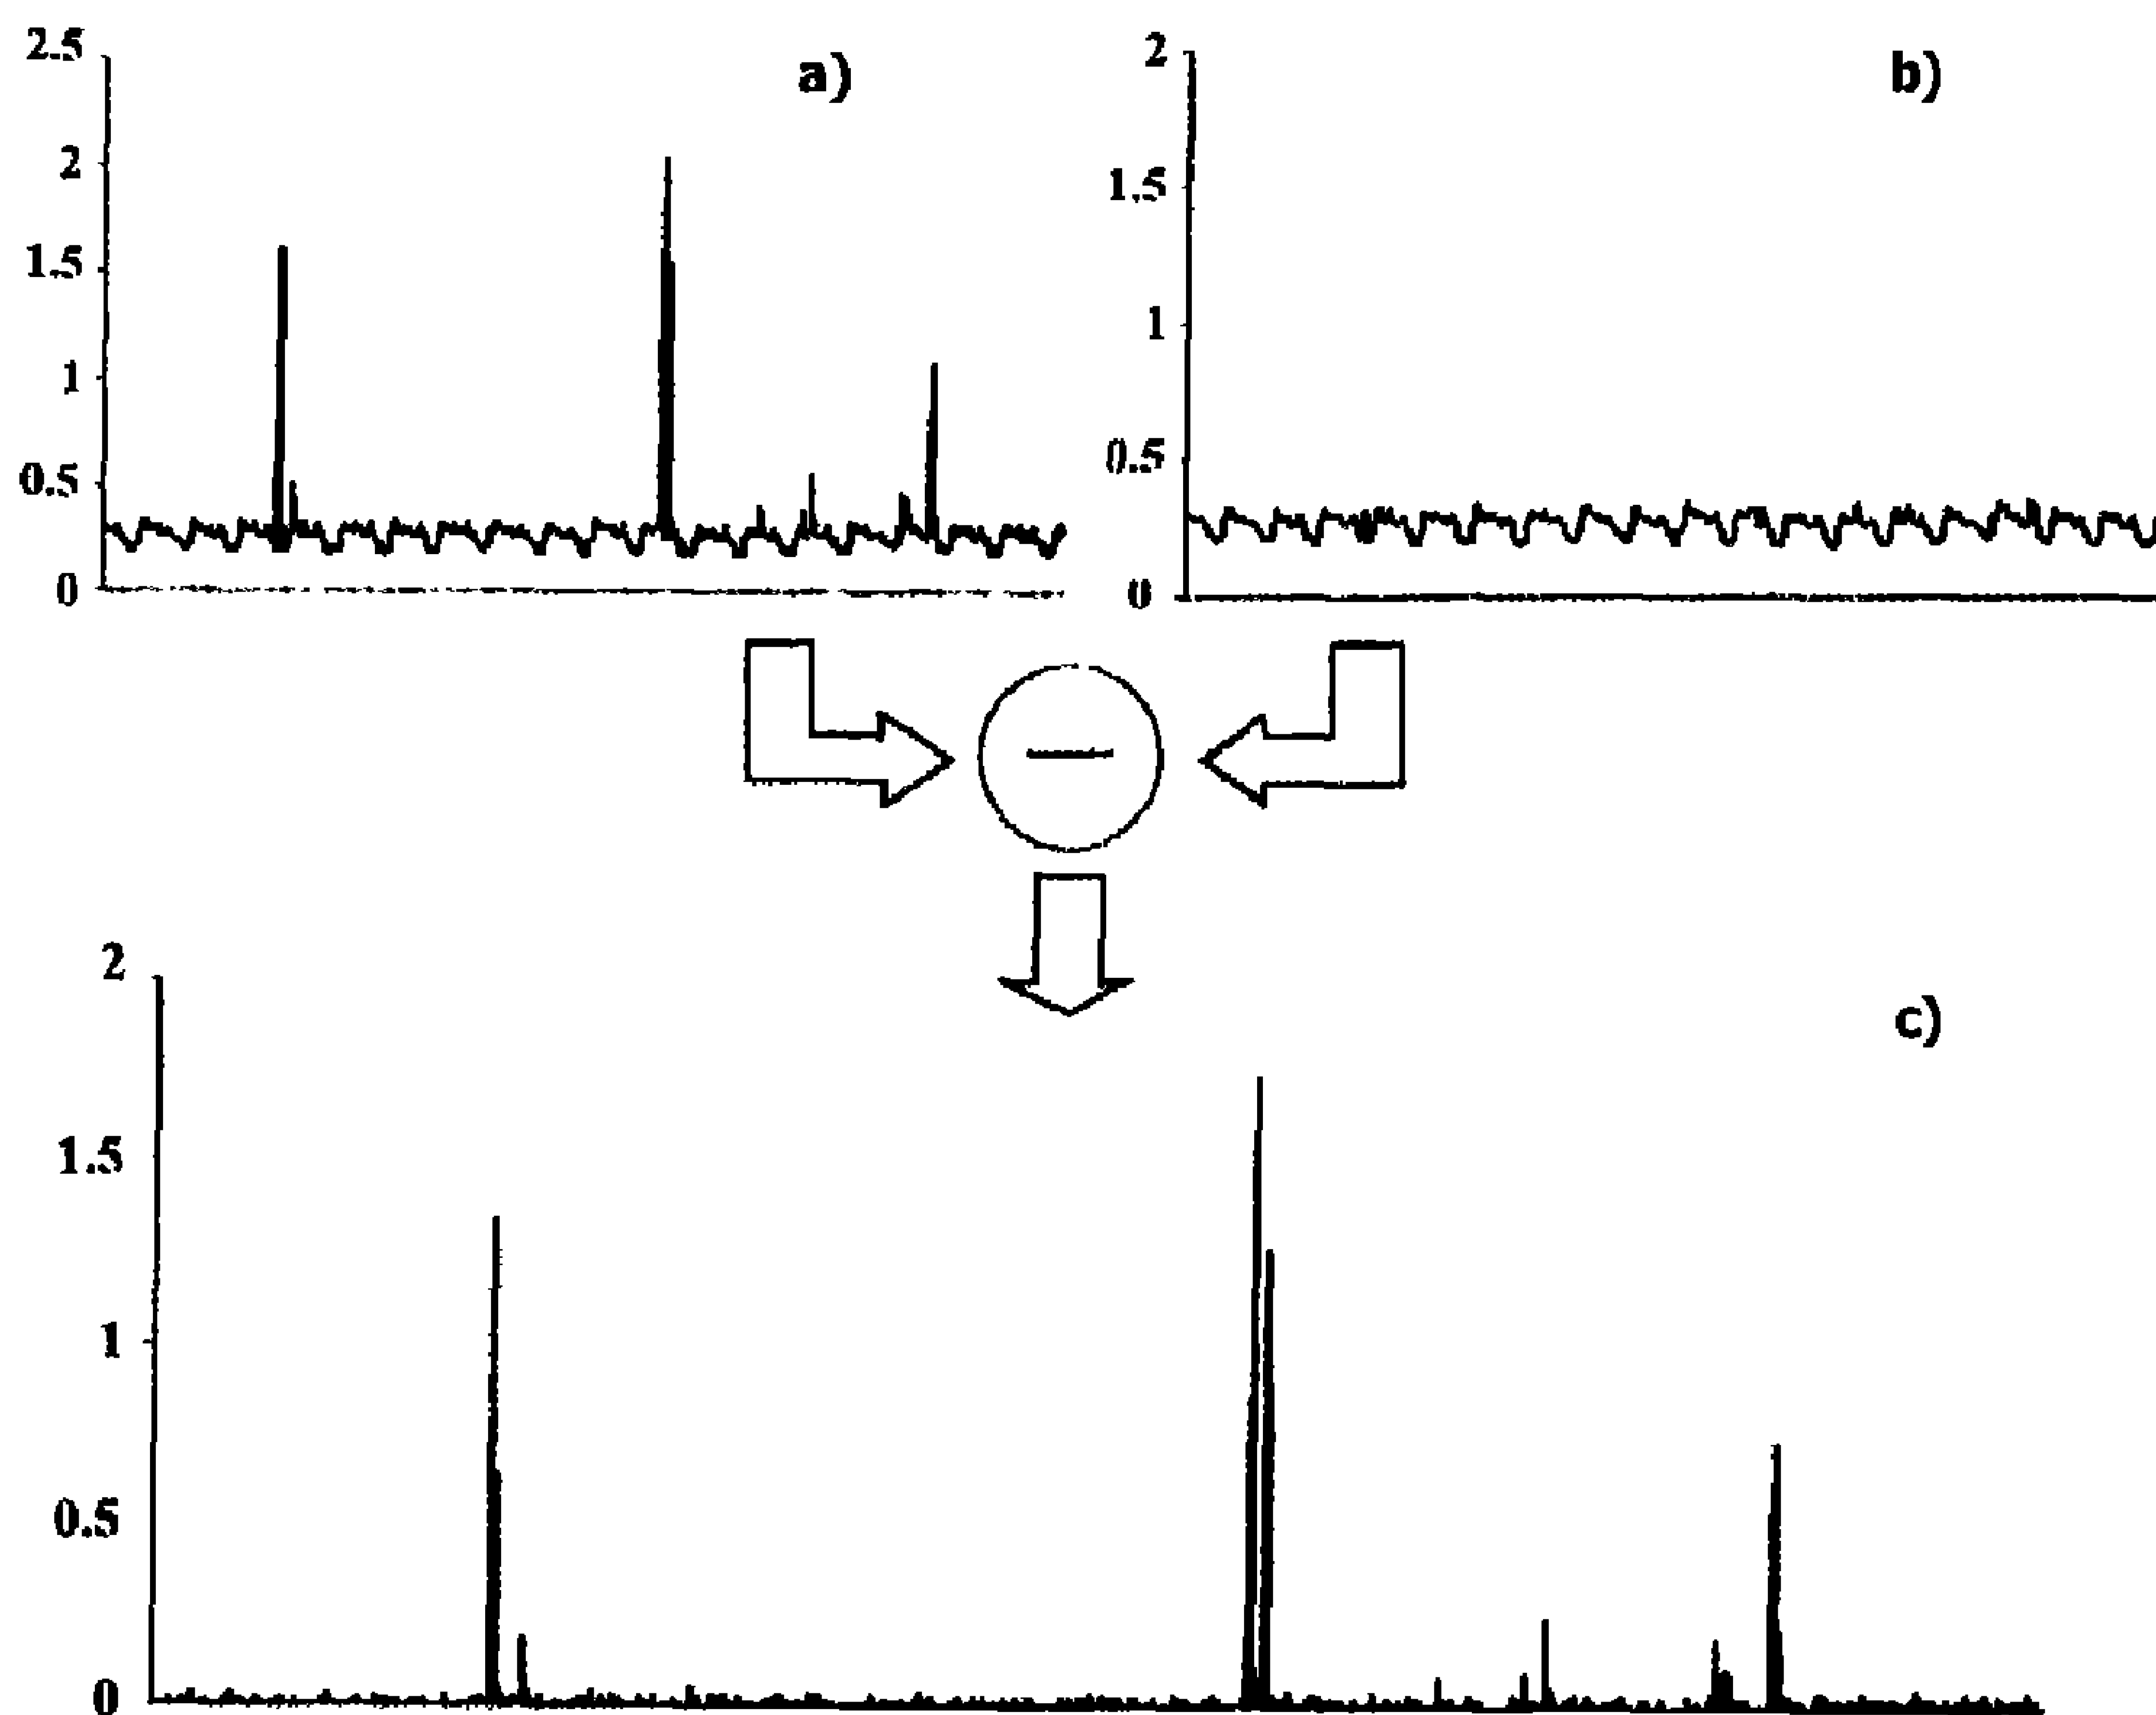
الهدف الآن هو توقع معدل التدفق المستقبلي الناتج عن المطر. تمتلك عادة هذه الإشارات علاقة تُظهر في الإشارة الأخرى، التي تُدوِّر إشارة مقياس المطر إلى ذلك التدفق. وتمتلك هذه الإشارة شكل توابع أسية متناقصة، تعمل كاستجابة لتحفيز النظام، الذي يُربط بكلا الإشارتين.

هناك طريقة مختلفة: نحاول الحصول على نظام يربط منسوب المطر (الشكلين 7 و8) إلى معدل التدفق (الشكلين 9 و10). أما الآن، فالهدف هو إيجاد إشارة تنمذج النظام المرغوب وفقاً للعلاقة بين كلا الإشارتين.

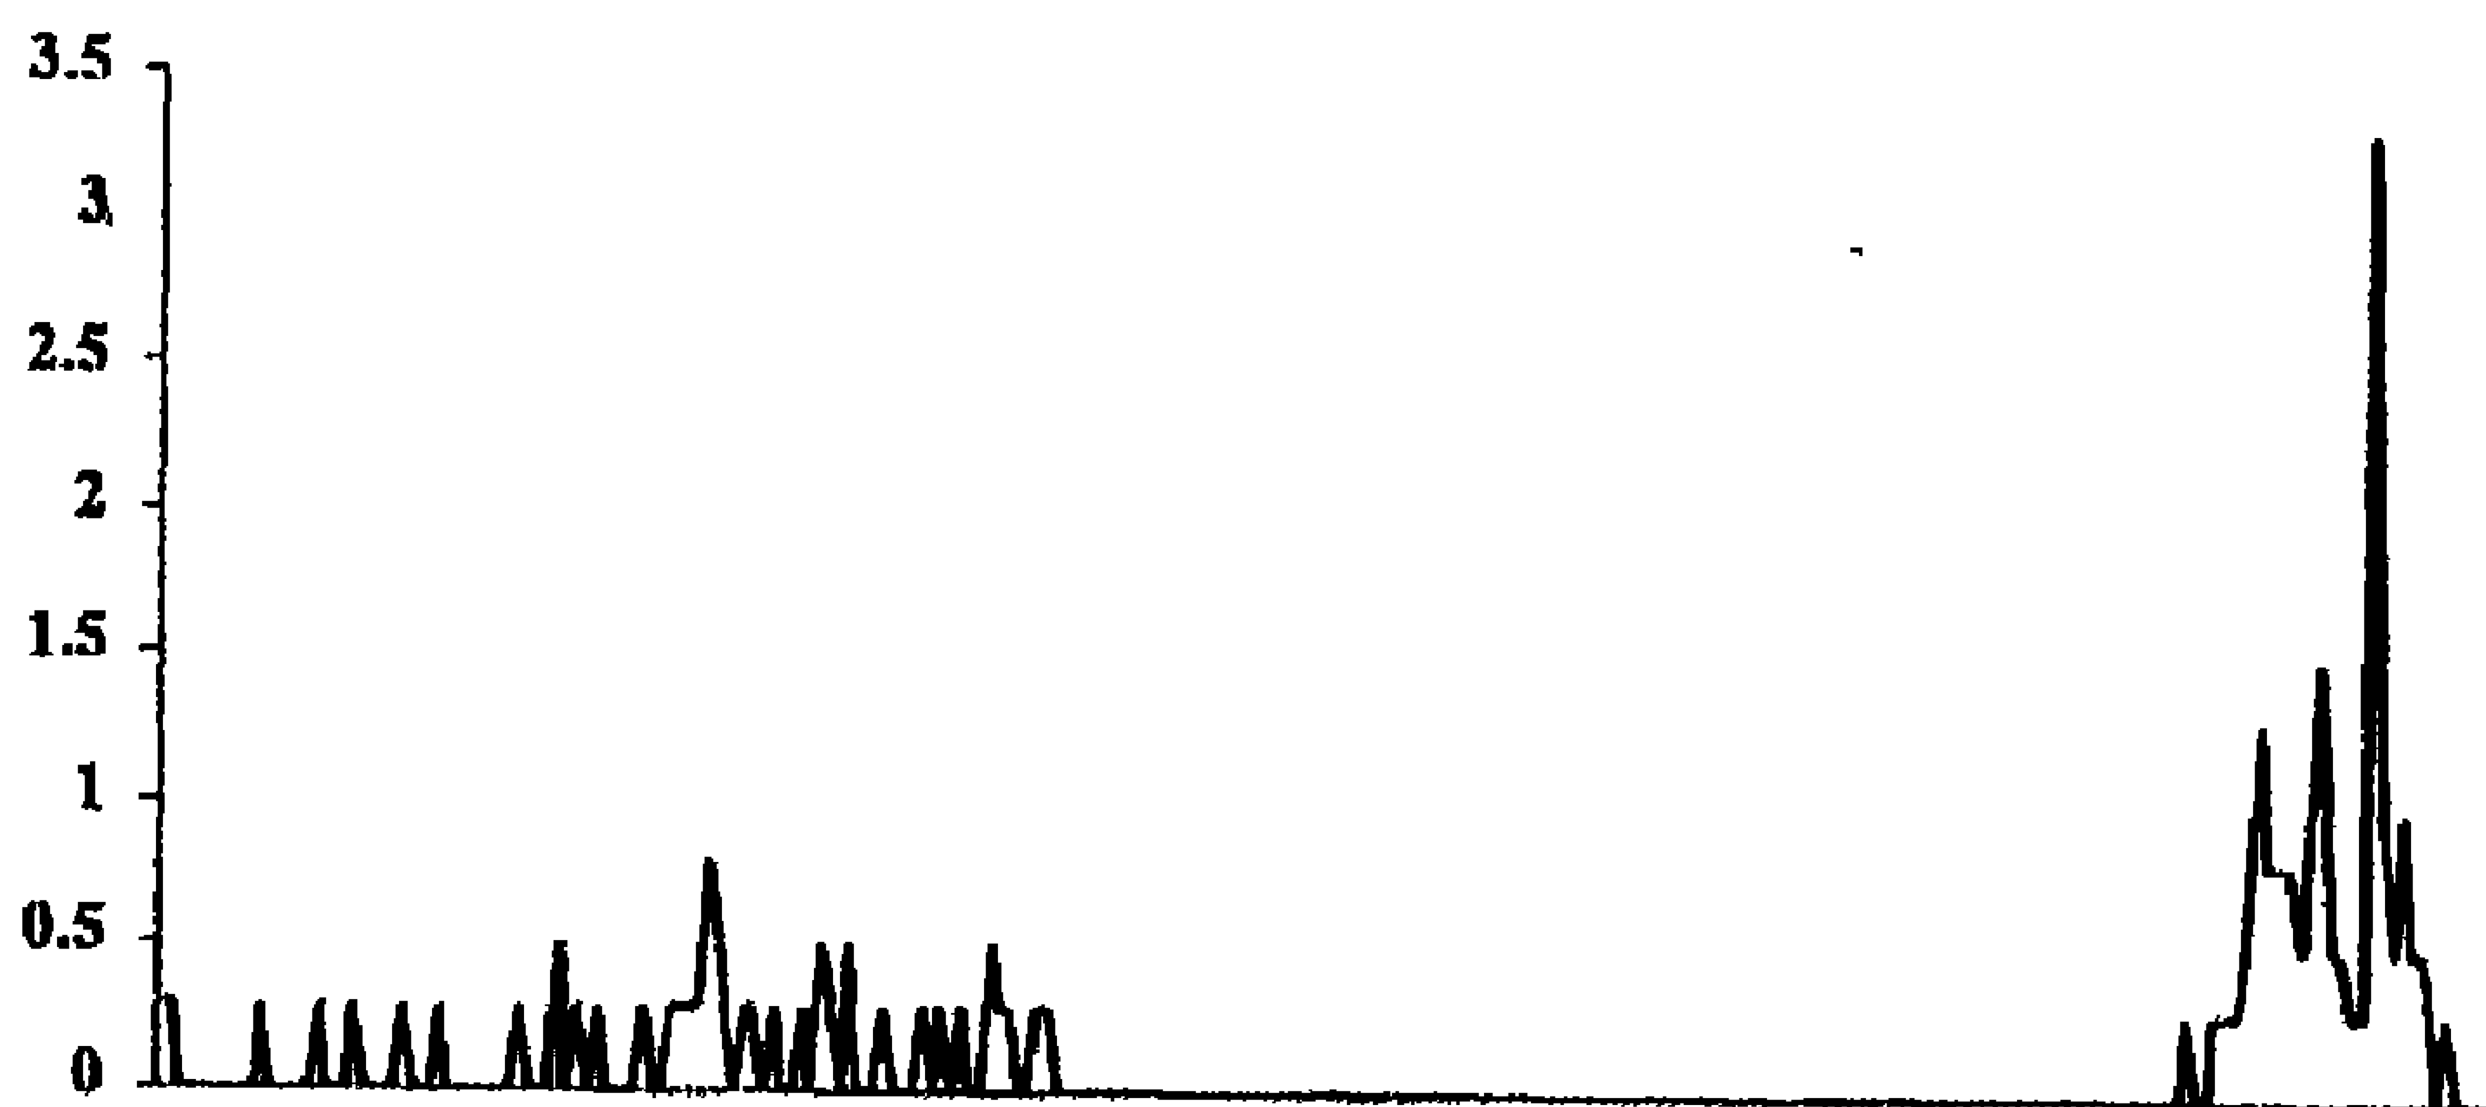
الشكل (7) *إشارة مقياس المطر (ملف دخل تدريبي _ 5426 نقطة بيانات).*



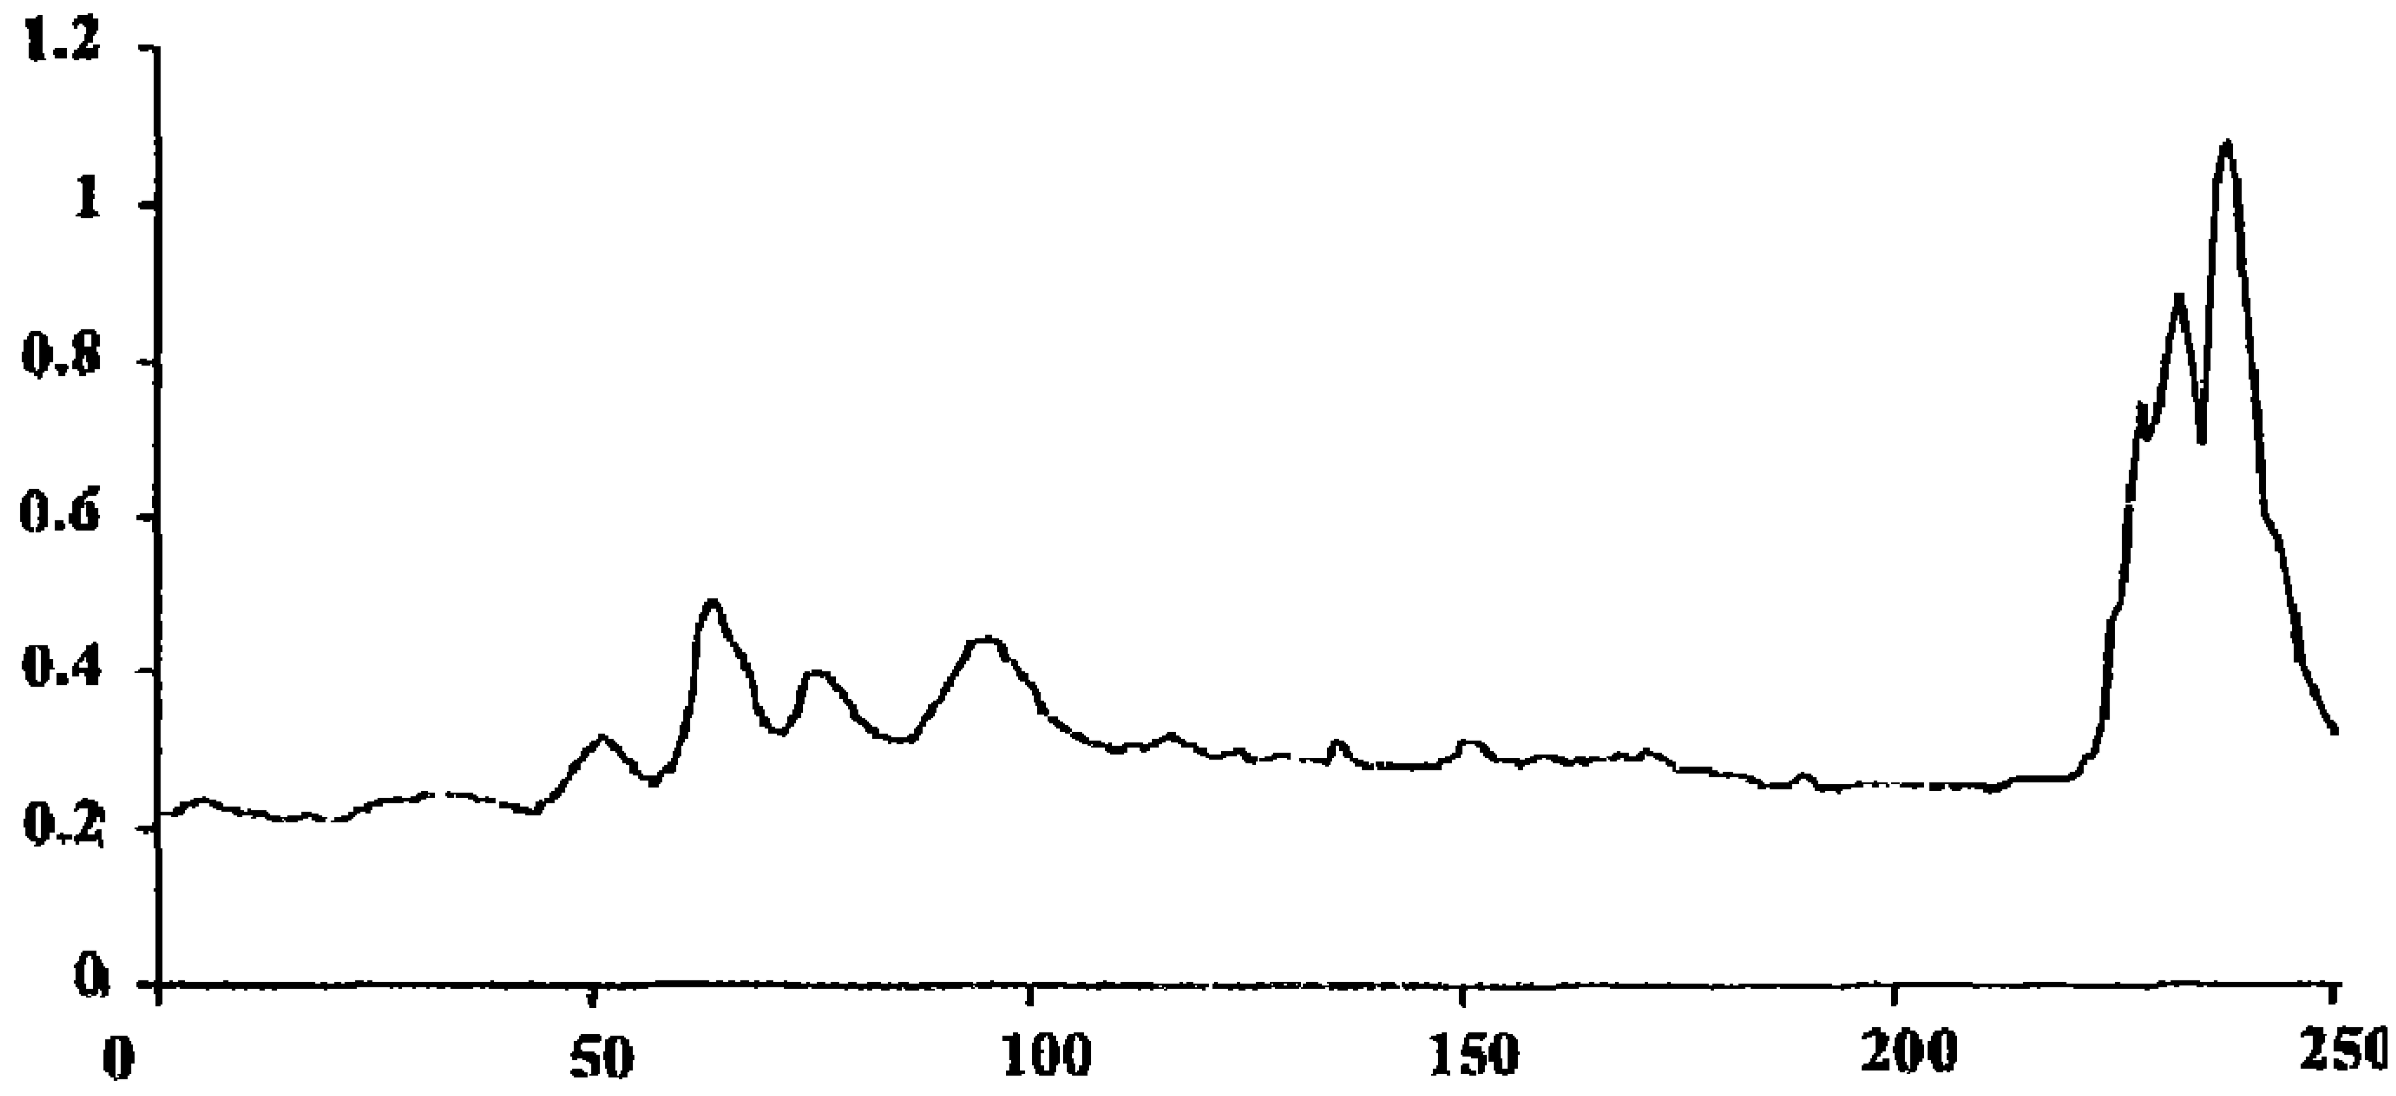
الشكل (8) المخطط البياني (a) - إشارة معدل التدفق الحقيقي (التدفق اليومي ومنسوب التدفق المُسبب بالمطر). المخطط البياني (b) - التدفق اليومي. المخطط البياني (c) - منسوب التدفق المُسبب بالمطر (ملف التدريب - 5426 نقطة بيانات).



الشكل (9) إشارة مقياس المطر (ملف دخل اختباري - 250 نقطة بيانات)



***الشكل (10)** إشارة معدل التدفق (ملف خرج اختباري - 250 نقطة بيانات).*



عادةً في مجال الهيدرولوجي، تمتلك هاتان الإشارتان (هطول المطر والتدفق الناتج عن المطر) علاقة، يمكن أن تربط بتابع النقل المسمى بالمِخطاط المائي الوَحْديّ. هذا المخطاط المائي الوَحْديّ – الذي يعمل كاستجابة لتحفيز مزوّد بإشارة هطول المطر – يمكن أن يُعبر عنه بواسطة بعض التعابير الرياضية، غير أن أكثر تلك التعابير شيوعاً هي التوابع الأسية المتناقصة، التي يمكن أن تأخذ بالحسبان عمليات الانحسار.

سوف تُستخدم أربع طرق مختلفة بغية تحديد أي منها يملك الأداء الأفضل لهذه المهمة. وهذه الطرق الأربع هي:

- تابع الانحدار الخطي.
- ANN التكرارية.
- البرمجة الوراثية (GP).
- المِخطاط المائي الوَحْديّ SCS.

نمذجة تدفق المطر بتابع انحدار خطي

تتضمن الطريقة الأولى الأساسية للتوقع استخدام طريقة انحدار خطية. وهذا يستلزم استخدام تابع كالآتي:

f(x) = m * x + b

بهذا الأسلوب، يمكن أن يُحلل السلوك لكلا الإشارتين بهذا النوع من التوقع. التابع الأكثر ملاءمة لتوقع التدفق هو:

f(x) = 4.3912 x + 0.1595

ينتج هذا التابع خطأً تربيعياً متوسطاً (MSE) قدره 0.0168، وخطأً متوسطاً (ME) مقداره 0.0770 على ملف الاختبار. يمكننا أن نلاحظ في (الشكل 11) المقارنة بين معدل التدفق الحقيقي وتوقع تابع الانحدار على ملف الاختبار.

الشكل (11) *إشارة معدل التدفق ونتيجة توقع تابع الانحدار (ملف اختبار).*



نمذجة تدفق المطر بواسطة RANN

البنية الهندسية لــ RANN التي تعطي النتائج الأفضل هي كالآتي :

- 3 عصبونات: عصبون دخل، عصبون خرج، عصبون خفي.
- تابع التفعيل: خطي (f = K x NET)

تنتج هذه MSE RANN مقداره 0.0037، وME مقداره 0.0343 على ملف الاختبار. في (الشكل 13) يمكننا أن نشاهد المقارنة بين معدل التدفق الحقيقي وتوقع RANN على ملف الاختبار.

نمذجة تدفق المطر بالبرمجة الوراثية

الهدف الرئيس هو تحقيق إشارة، يمكن أن تشكل النظام المُعّرف بالعلاقة بين كلا الإشارتين كما هو مبين في (الشكل 14).

يشكل هذا التعبير مرشحاً بين الإشارات، ويعني تحويل إشارة ادخل (منسوب المطر) إلى إشارة خرج (التدفق) (Dorado et at., 2002, 2003). يُوصف هذا التحويل بإشارة h(n)، تملك أيضاً الصيغة التالية:

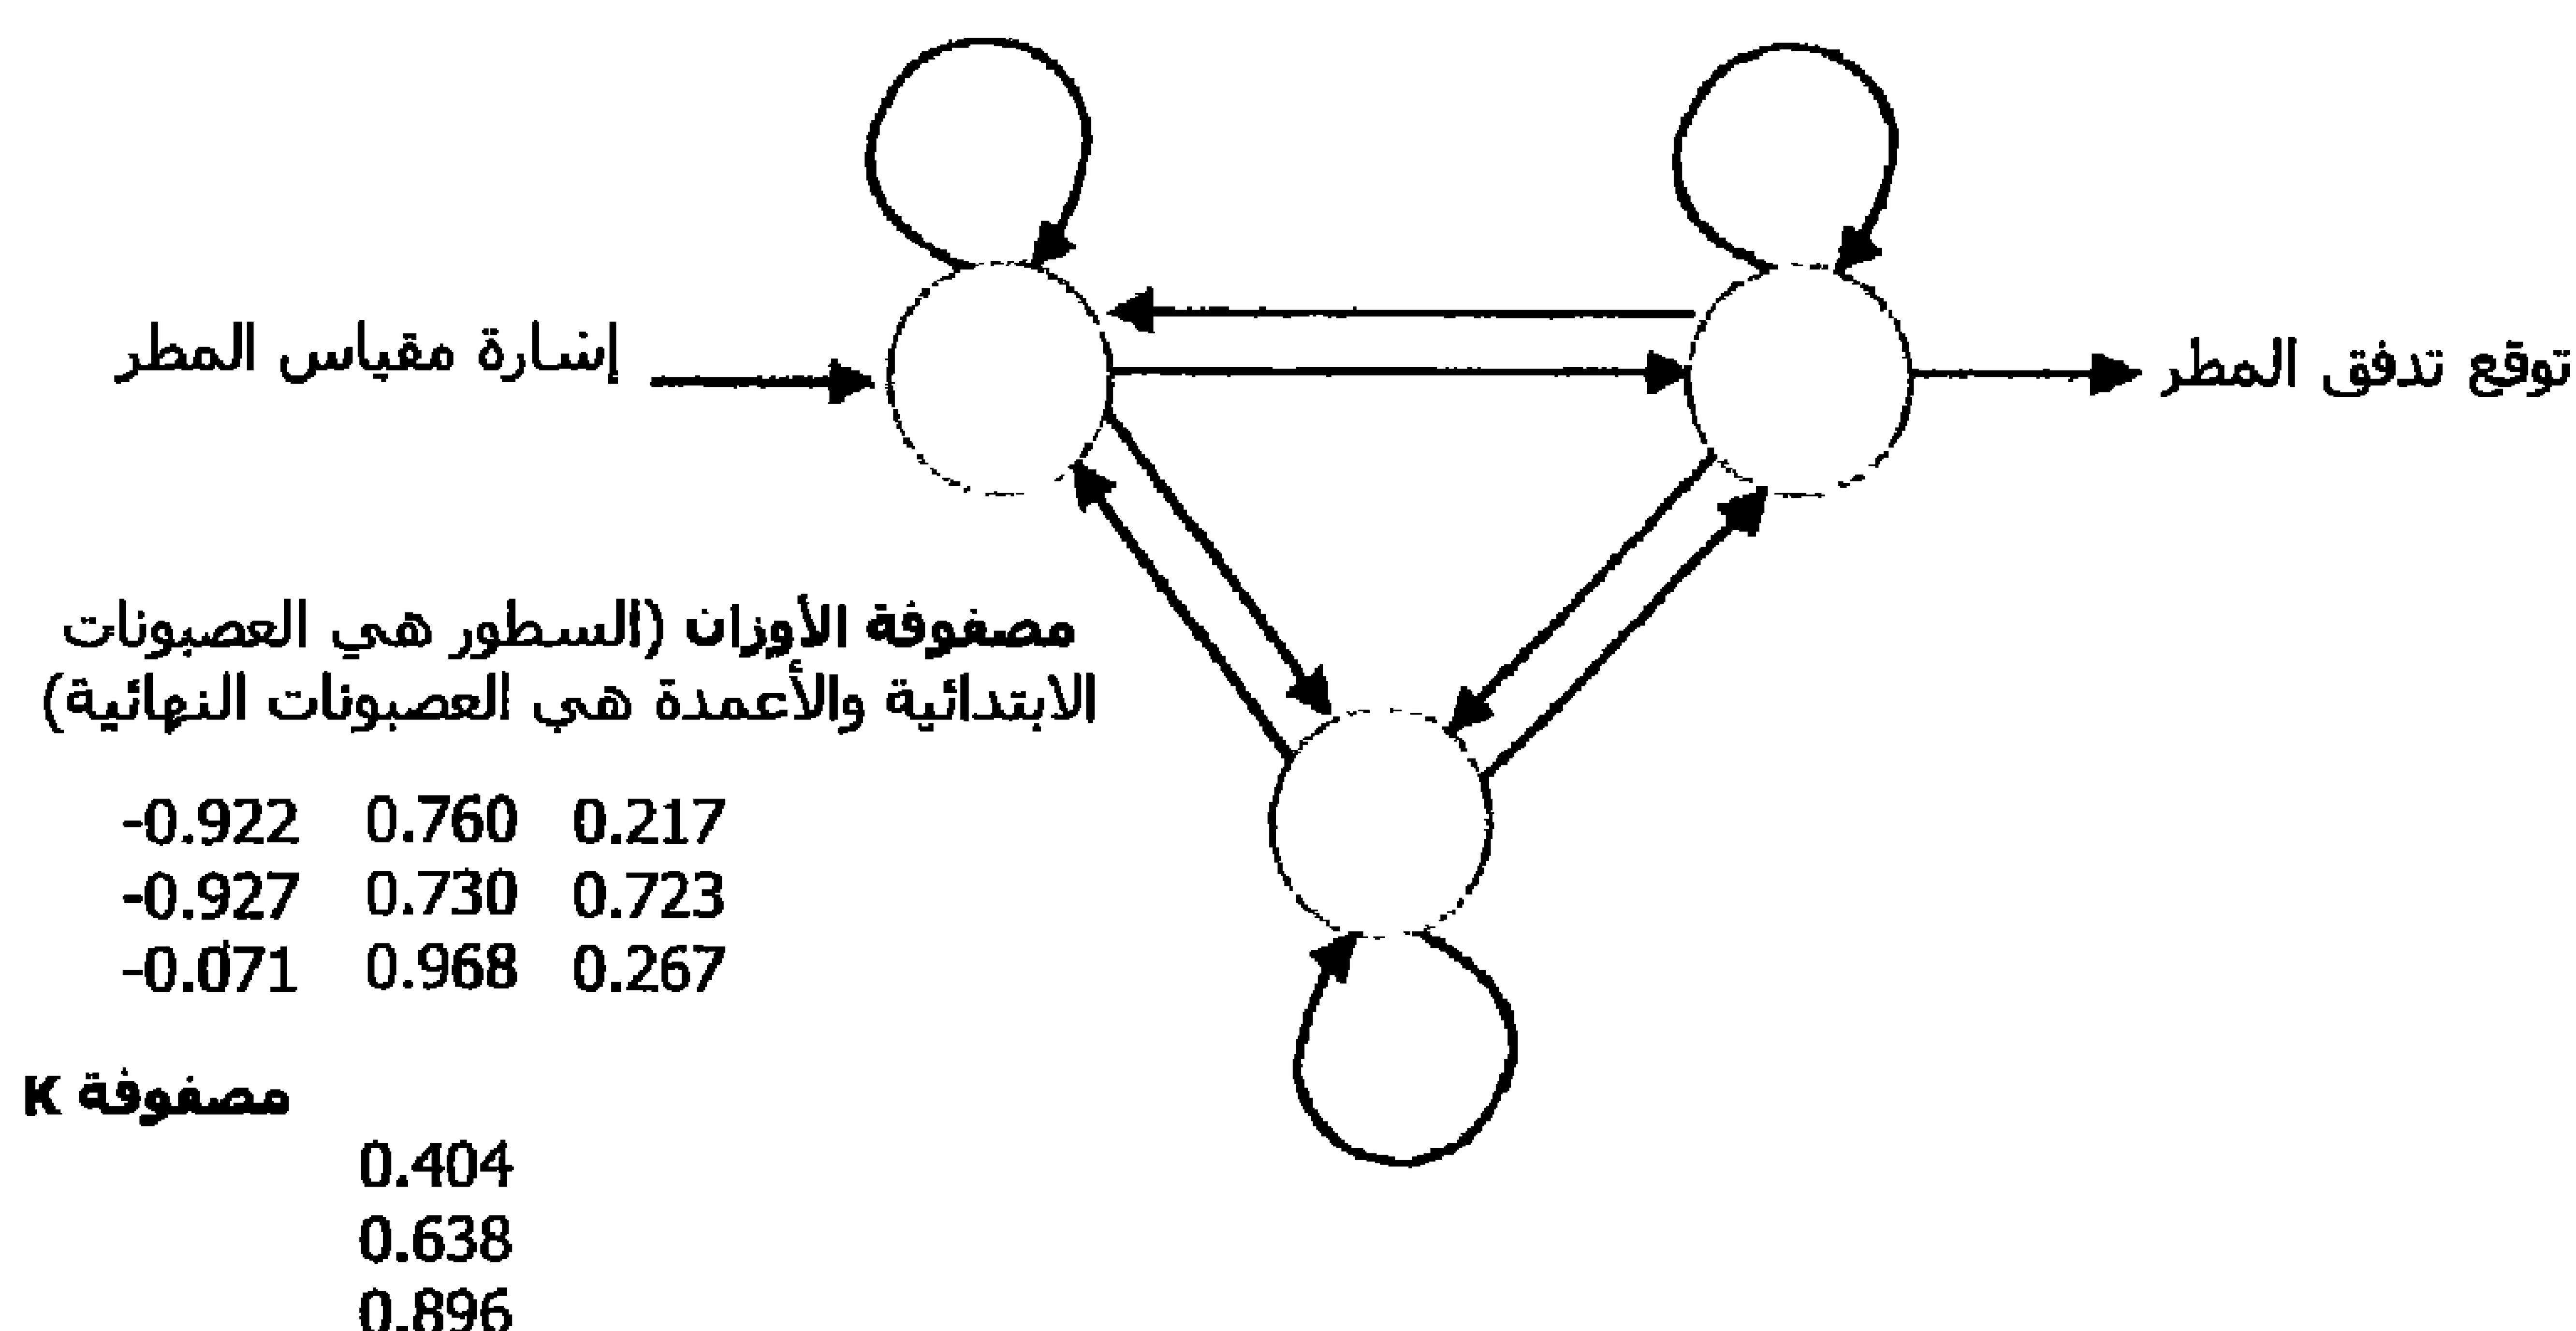
$$\sum_i C_i . e^{-k_i . n}$$

سيكون هذا عبارة عن نظام منفصل، وبالتالي فإن علاقة الإشارة مبينة في المعادلة مع اختلافات كالآتي:

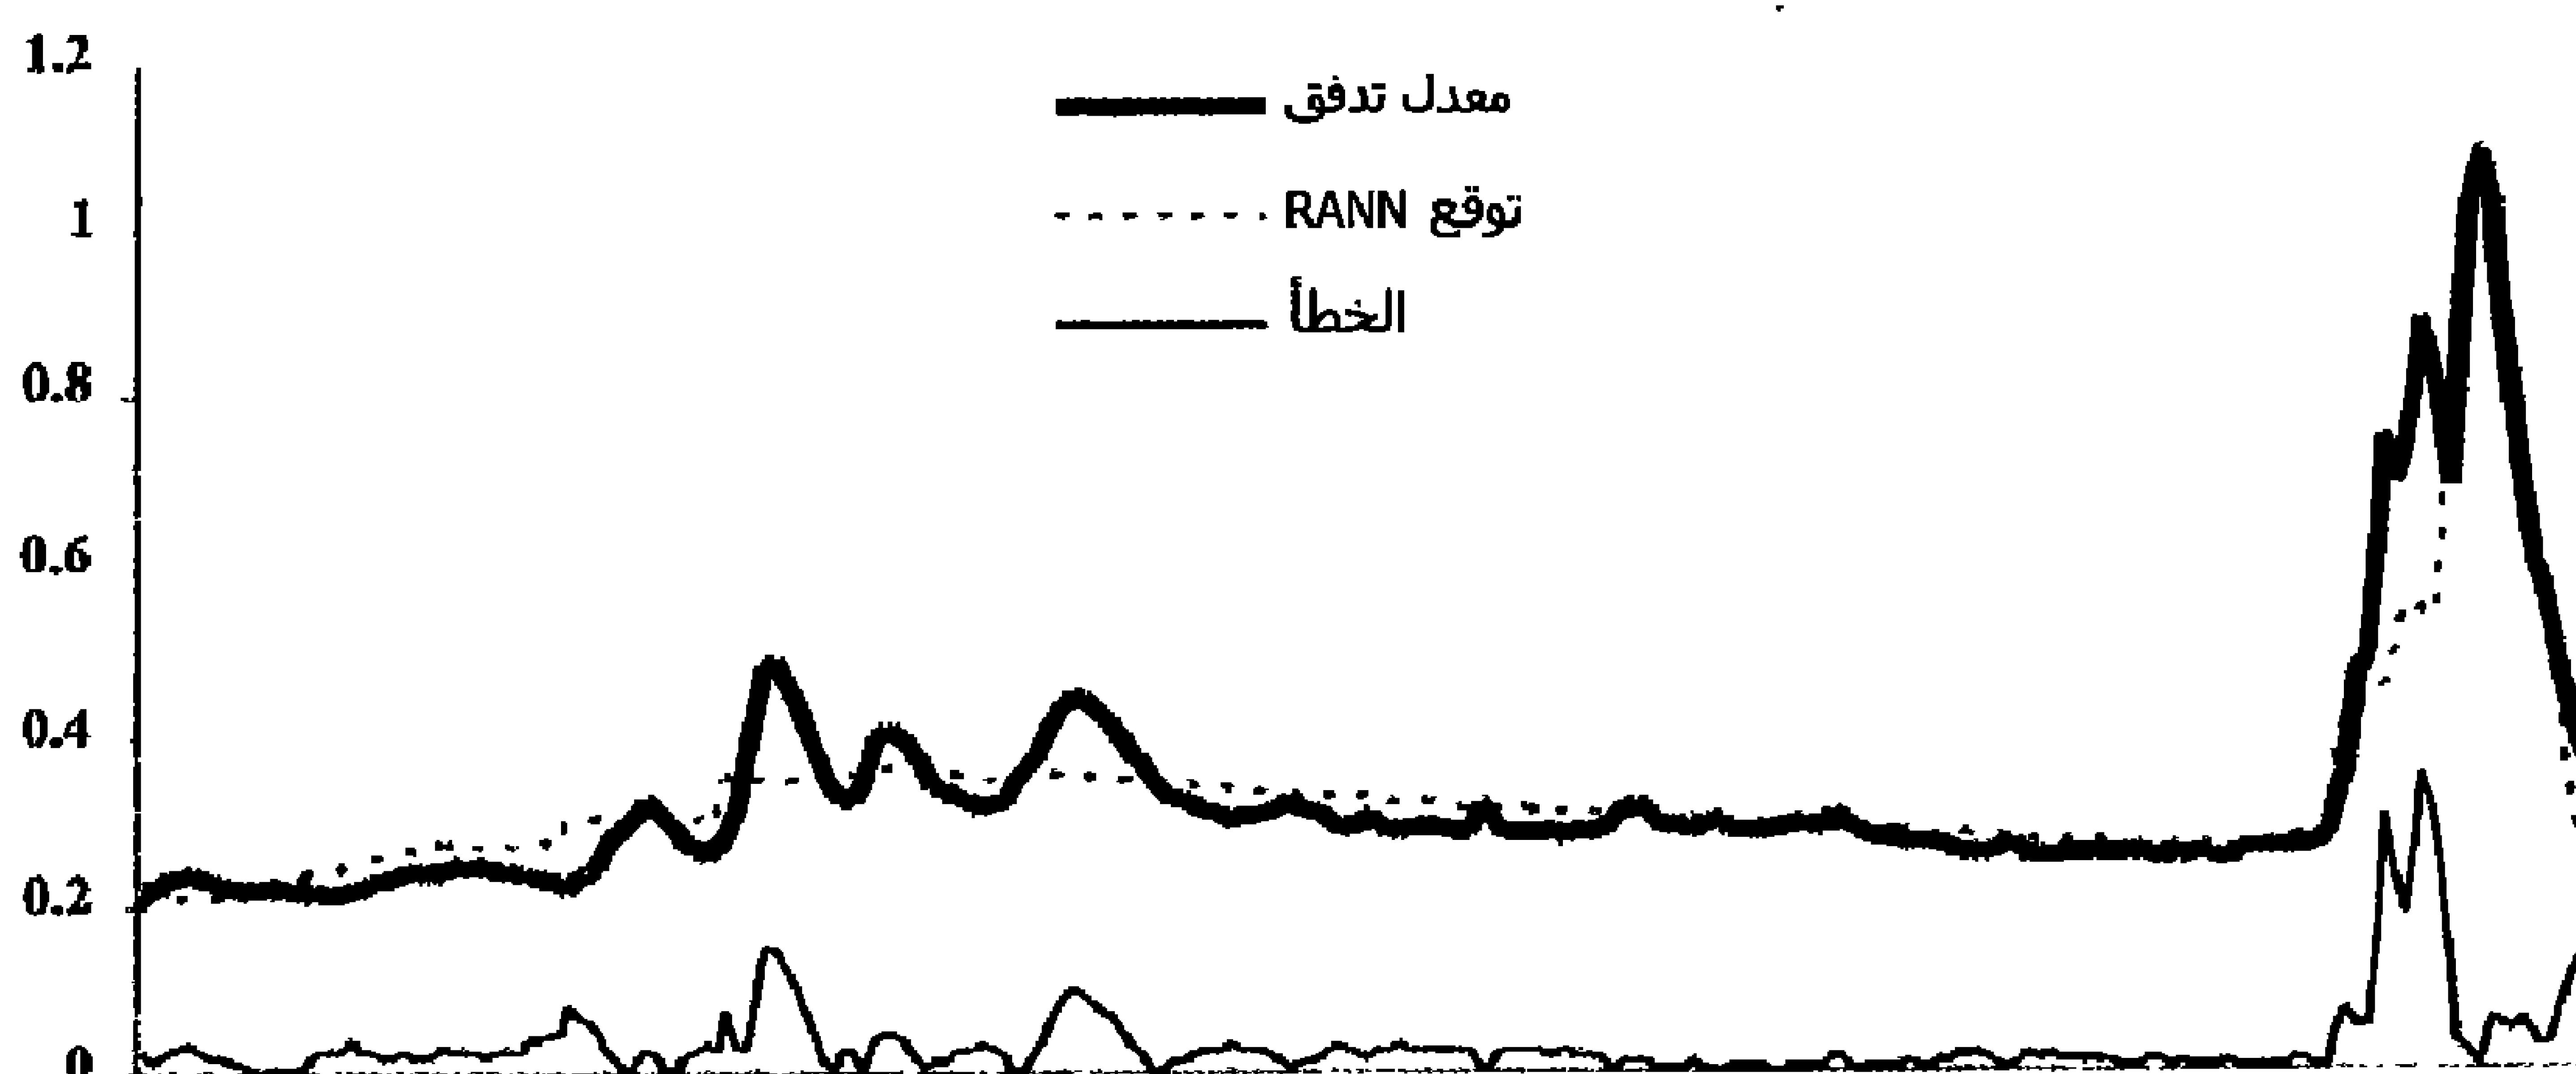
$$\sum_{i=0}^{M} b_i.y(n-i)=\sum_{i=0}^{N} a_i.x(n-i)$$

حيث أن: X(n) – إشارة الدخل. y(n) – إشارة الخرج. a_i, b_i – الثوابت التي ترتبط بالعينات التي أُزيلت من الدخل والخرج. M – عدد عينات الدخل المولد سابقاً التي استخدمت. N – عدد عينات الدخل السابق المستخدمة لتوليد الخرج.

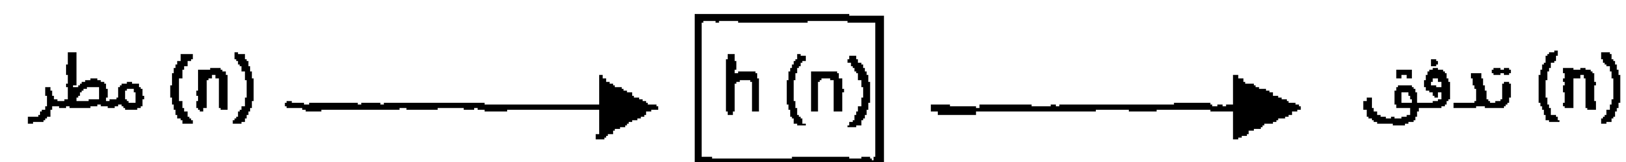
الشكل (12) *البنية الهندسية لـ RANN.*



الشكل (13) *إشارة معدل التدفق ونتيجة توقع RANN (ملف اختبار).*



الشكل (14) *العلاقة بين كلا الإشارتين التي سوف تُنمذج.*



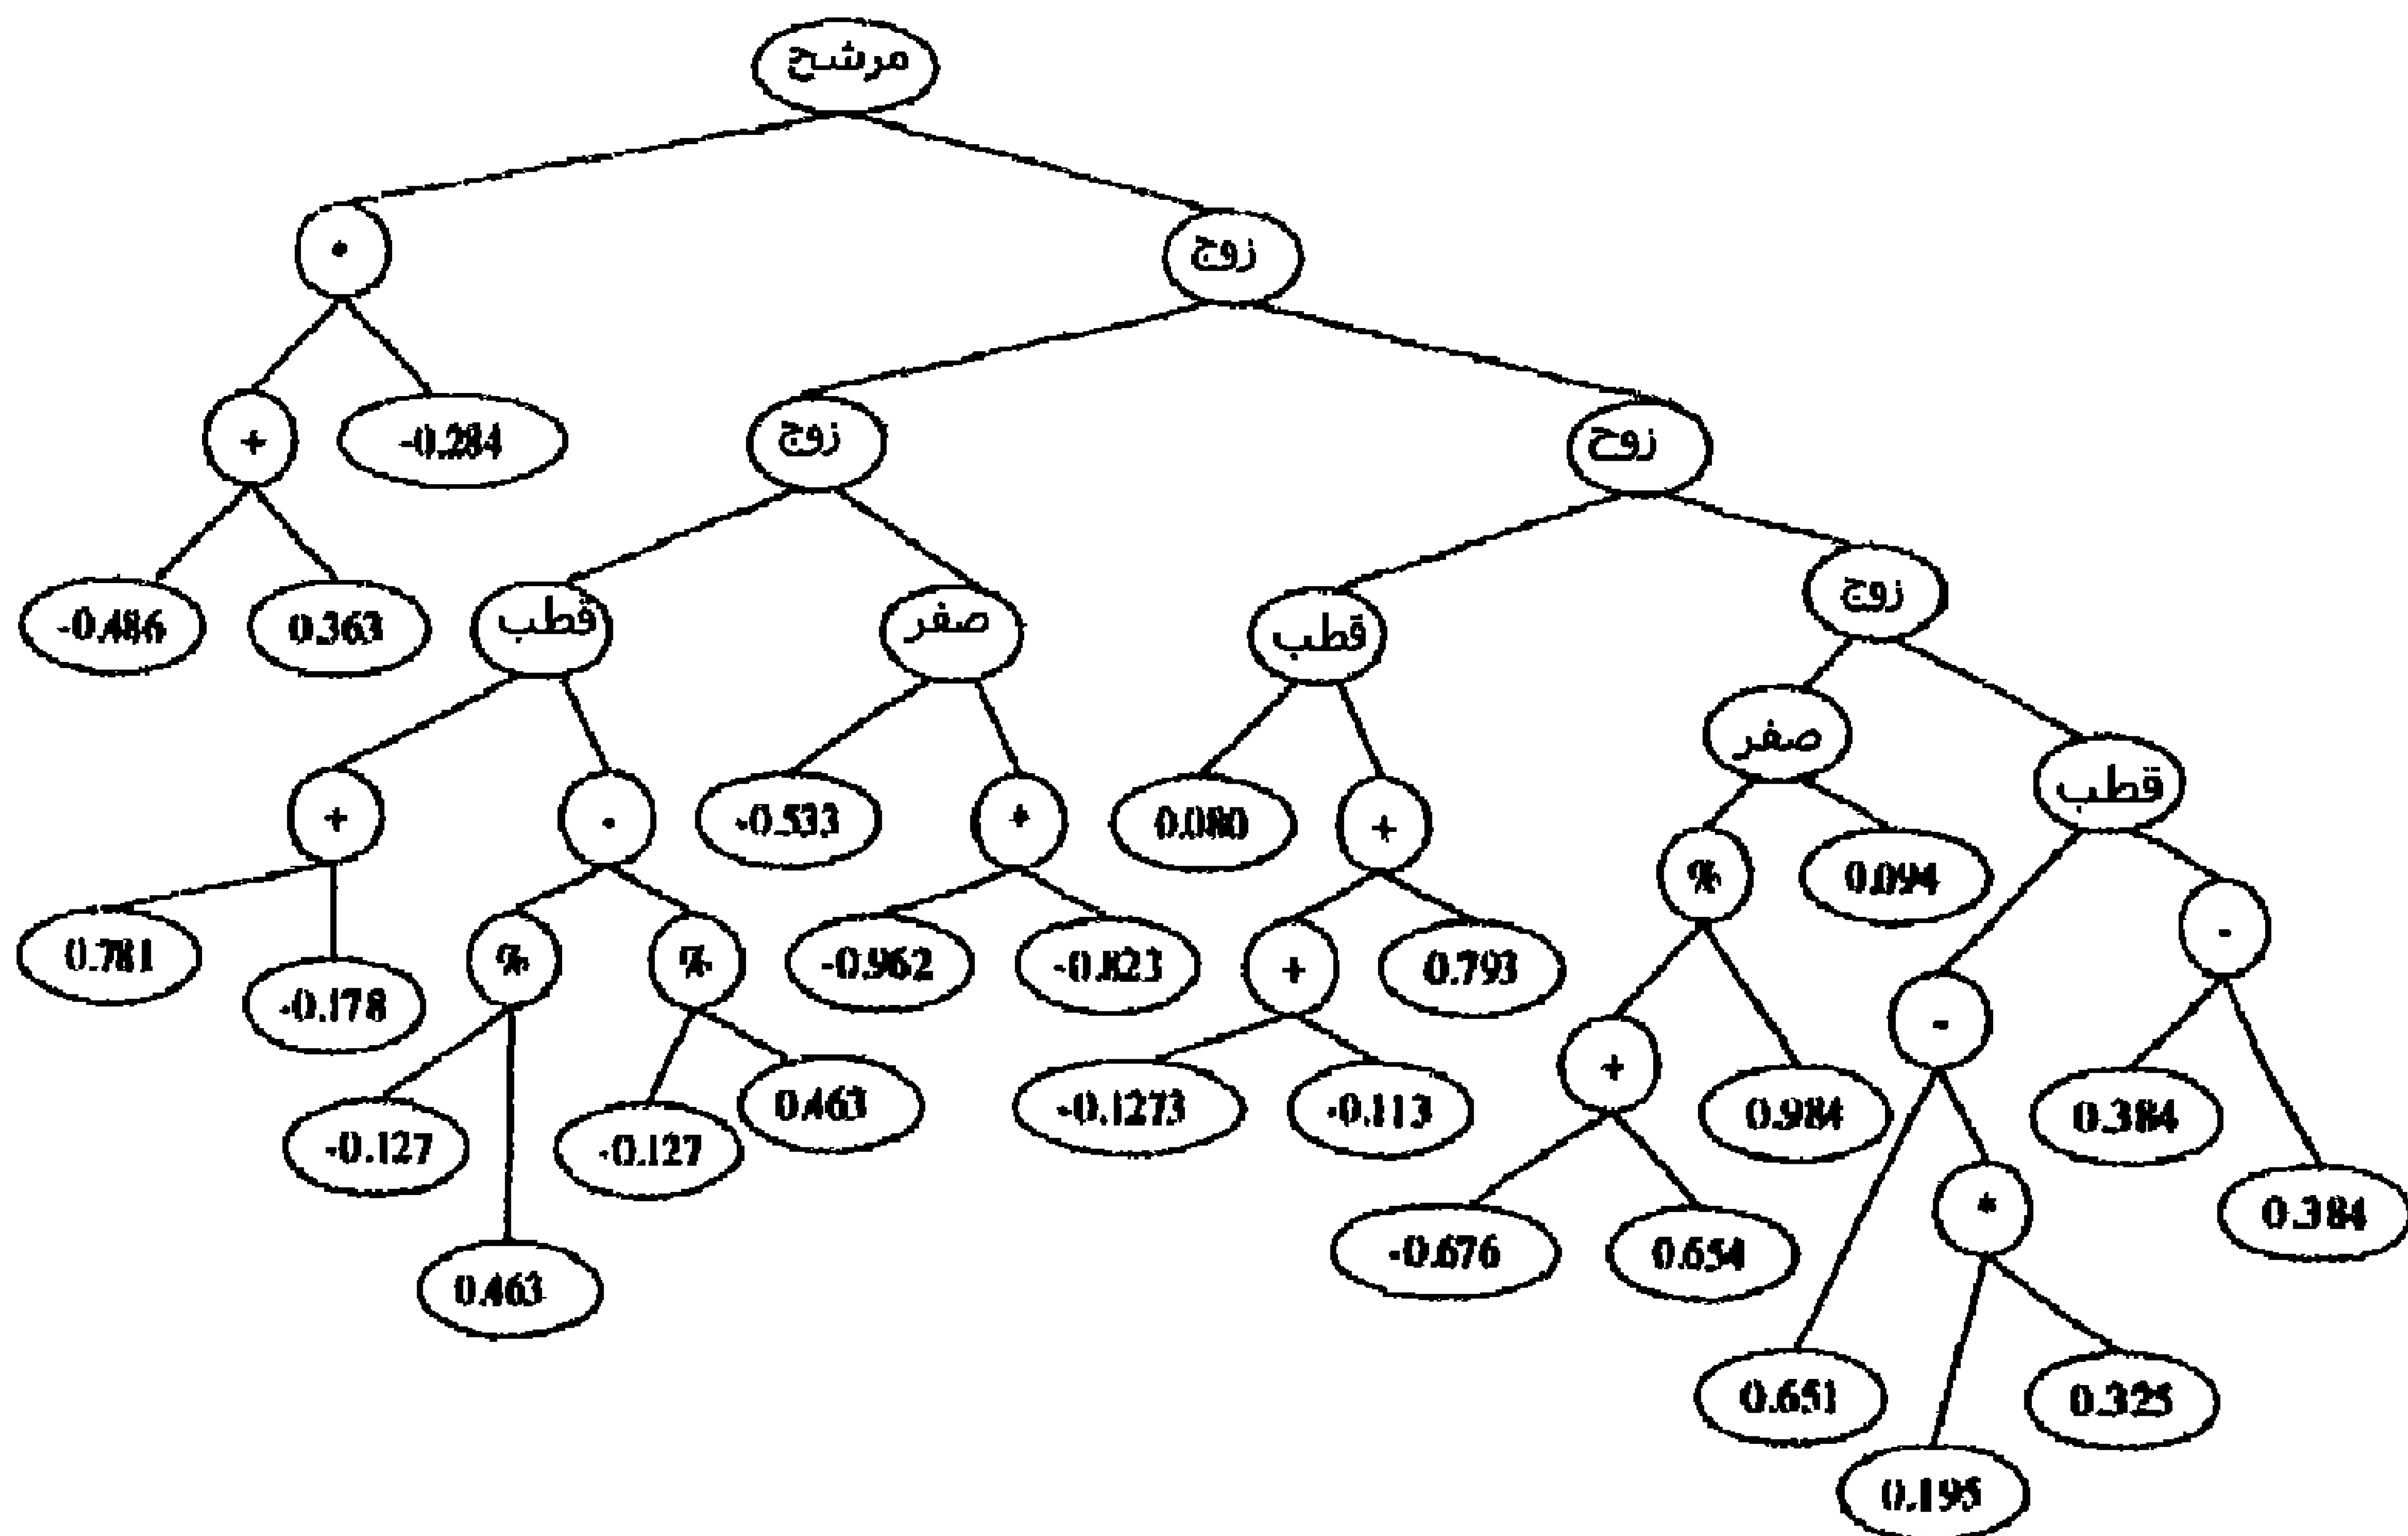
تُستخدم التشكيلة التالية بغية توليد مجموعات الأقطاب والأصفار:

- مجموعة عناصر طرفية = {مرشح، فردي، قطب، صفر، +، *، -، %)
- مجموعة عناصر طرفية = {[-1, 1]}.

تظهر الشجرة المُولّدة بواسطة GP والتي تعطي النتائج الأفضل في (الشكل 15). إذا تم تحويل هذه الشجرة إلى تعبير رياضي، فسوف نحصل على التعبير التالي:

$$y(n) = 0.0347 \,.\, x(n-1) + 0.0386 \,.\, x(n-2) + 0.0018 \,.\, x(n-3) + 0.0005 \,.\, x(n-4) + 1.3507 \,.\, y(n-1) - 0.8578 \,.\, y(n-2) + 0.4293 \,.\, y(n-3) - 0.1109 \,.\, y(n-4)$$

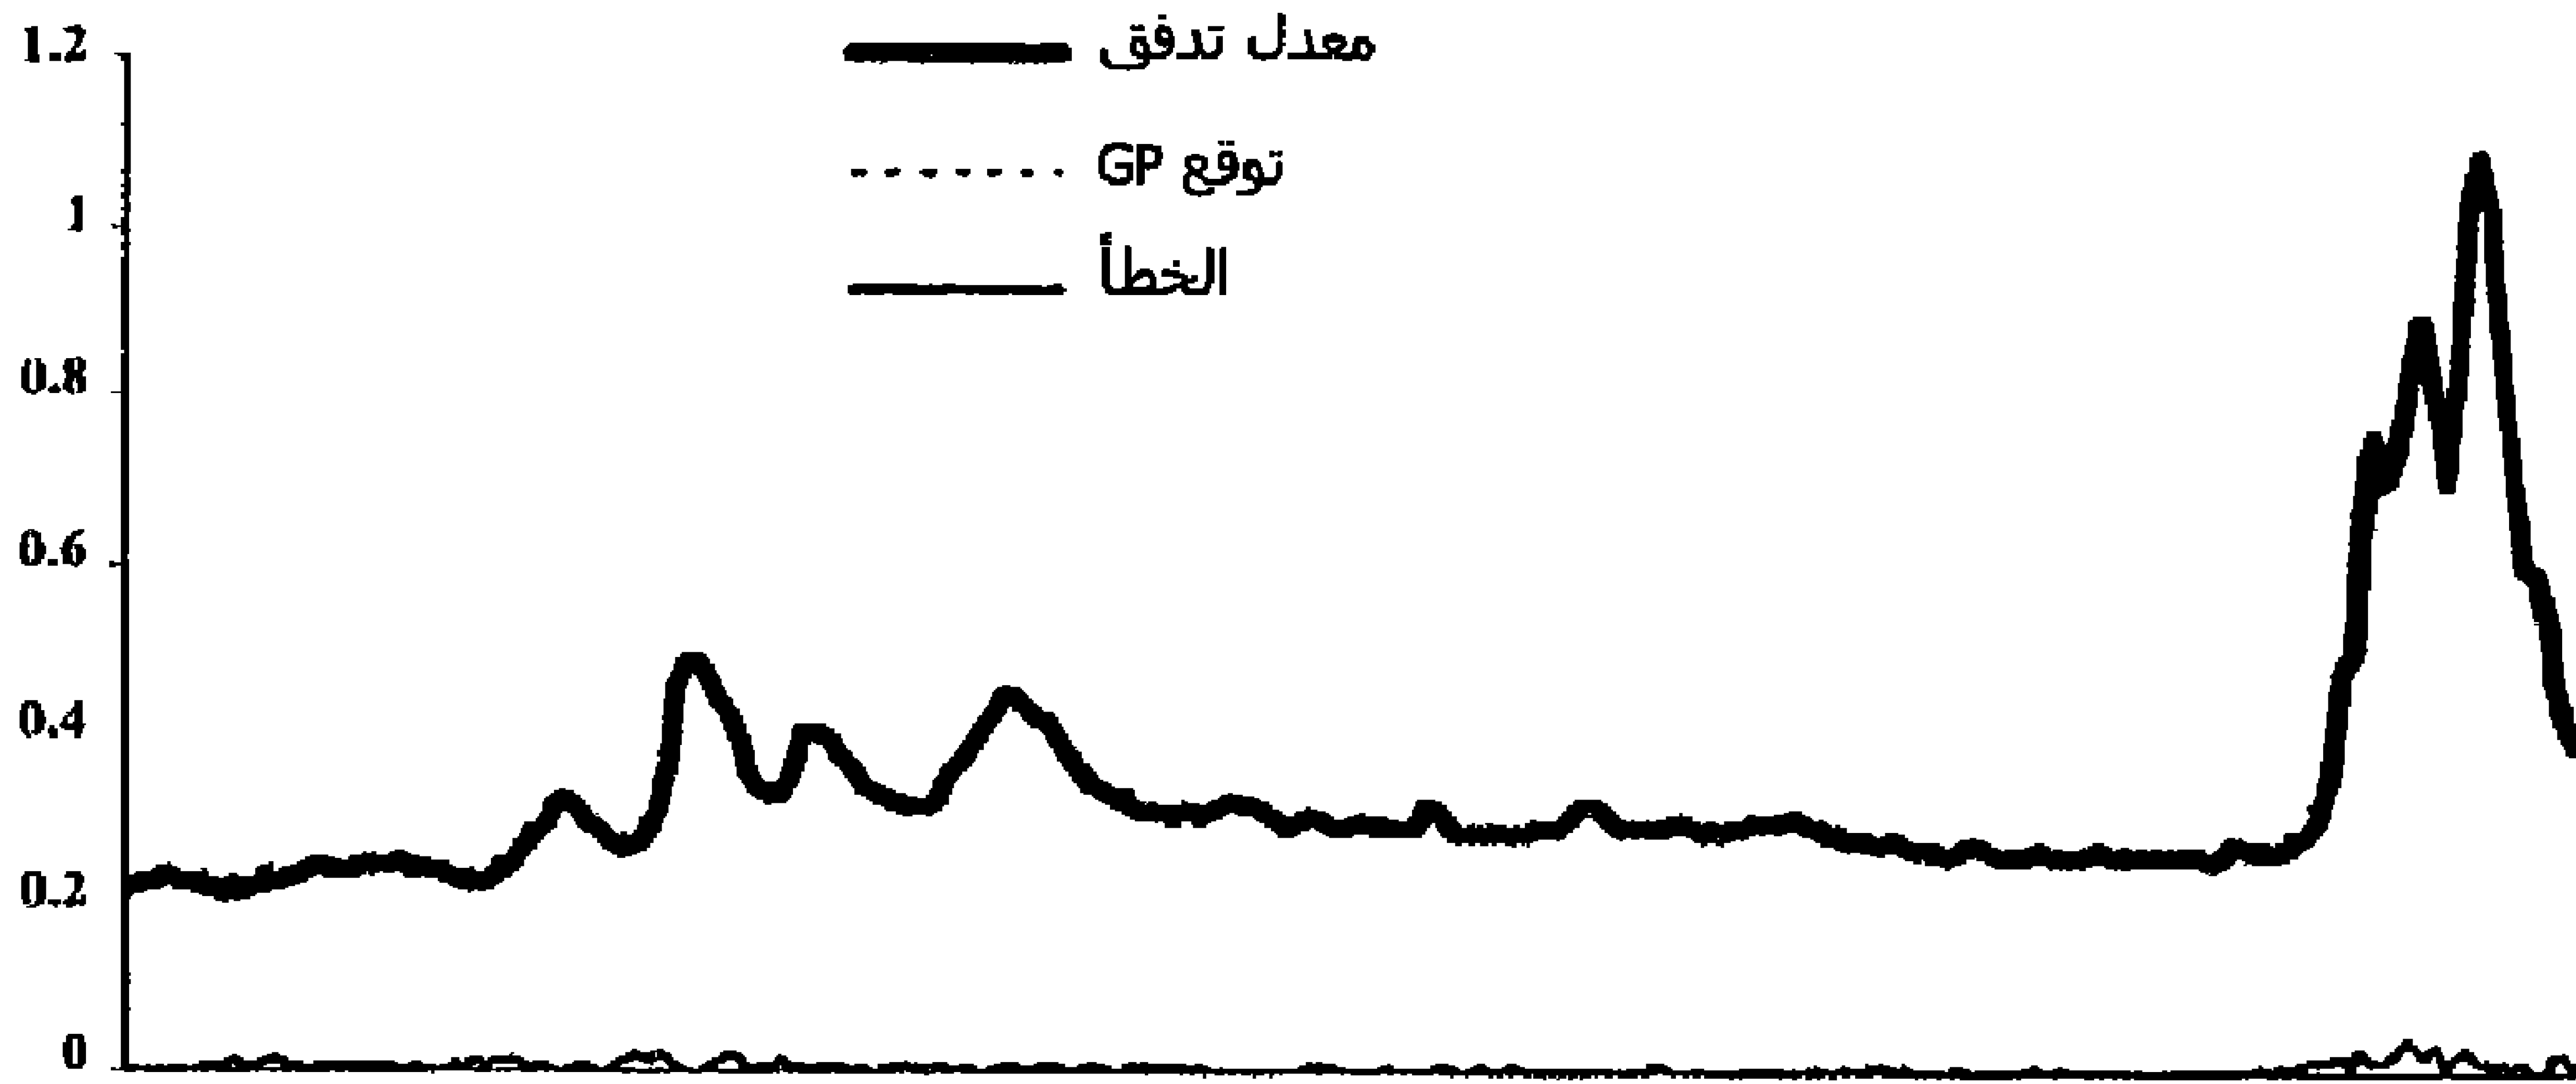
الشكل (15) *نتائج طريقة GP.*



يمكن التوسع في دراسة هذه الطريقة ونتائجها بالرجوع إلى المقالة "توقع ونمذجة تحويل الجريان السطحي لهطول المطر لحوض حرف مدينة نموذجي باستخدام ANN وGP" (Rabunal et at., 2003).

ينتج هذا التعبير MSE مقداره 0.0001 وME مقداره 0.0052 على ملف الاختبار. يمكننا نشاهد في (الشكل 16) مقارنة بين معدل التدفق والتنبؤ بعبارة GP على ملف الاختبار.

***الشكل (16)** إشارة معدل التدفق ونتيجة توقع تعبير GP (ملف اختبار).*



نمذجة تدفق المطر بمخطاط مائي وُحْدّي SCS

يمكن لخبراء الهيدرولوجي تطبيق طرق كمخطاط مائي وَحْديّ SCS من أجل هذا النوع من حوض صرف مدينة. بهذه الطريقة، يمكن أن يُنفذ تحليل الاستجابة بواسطة بيانات النبضة الوحدية، التي تعني استجابة المنظومة لـــ 1 مم من هبوط الماء.

كما يمكن أن تُستخدم طرق أخرى معتمدة على المعادلات الهيدروليكية، غير أنها أكثر تعقيداً وتكلفتها بخصوص زمن العمل مختلفة تماماً عن الطريقة المقترحة هنا.

يعطي المخطاط المائي الوَحْديّ MES مقداره 0.0056 وME مقداره 0.0428 على ملف الاختبار. يظهر (الشكل 17) مقارنة بين معدل التدفق الحقيقي وتوقع المخطاط المائي الوَحْديّ SCS على ملف الاختبار.

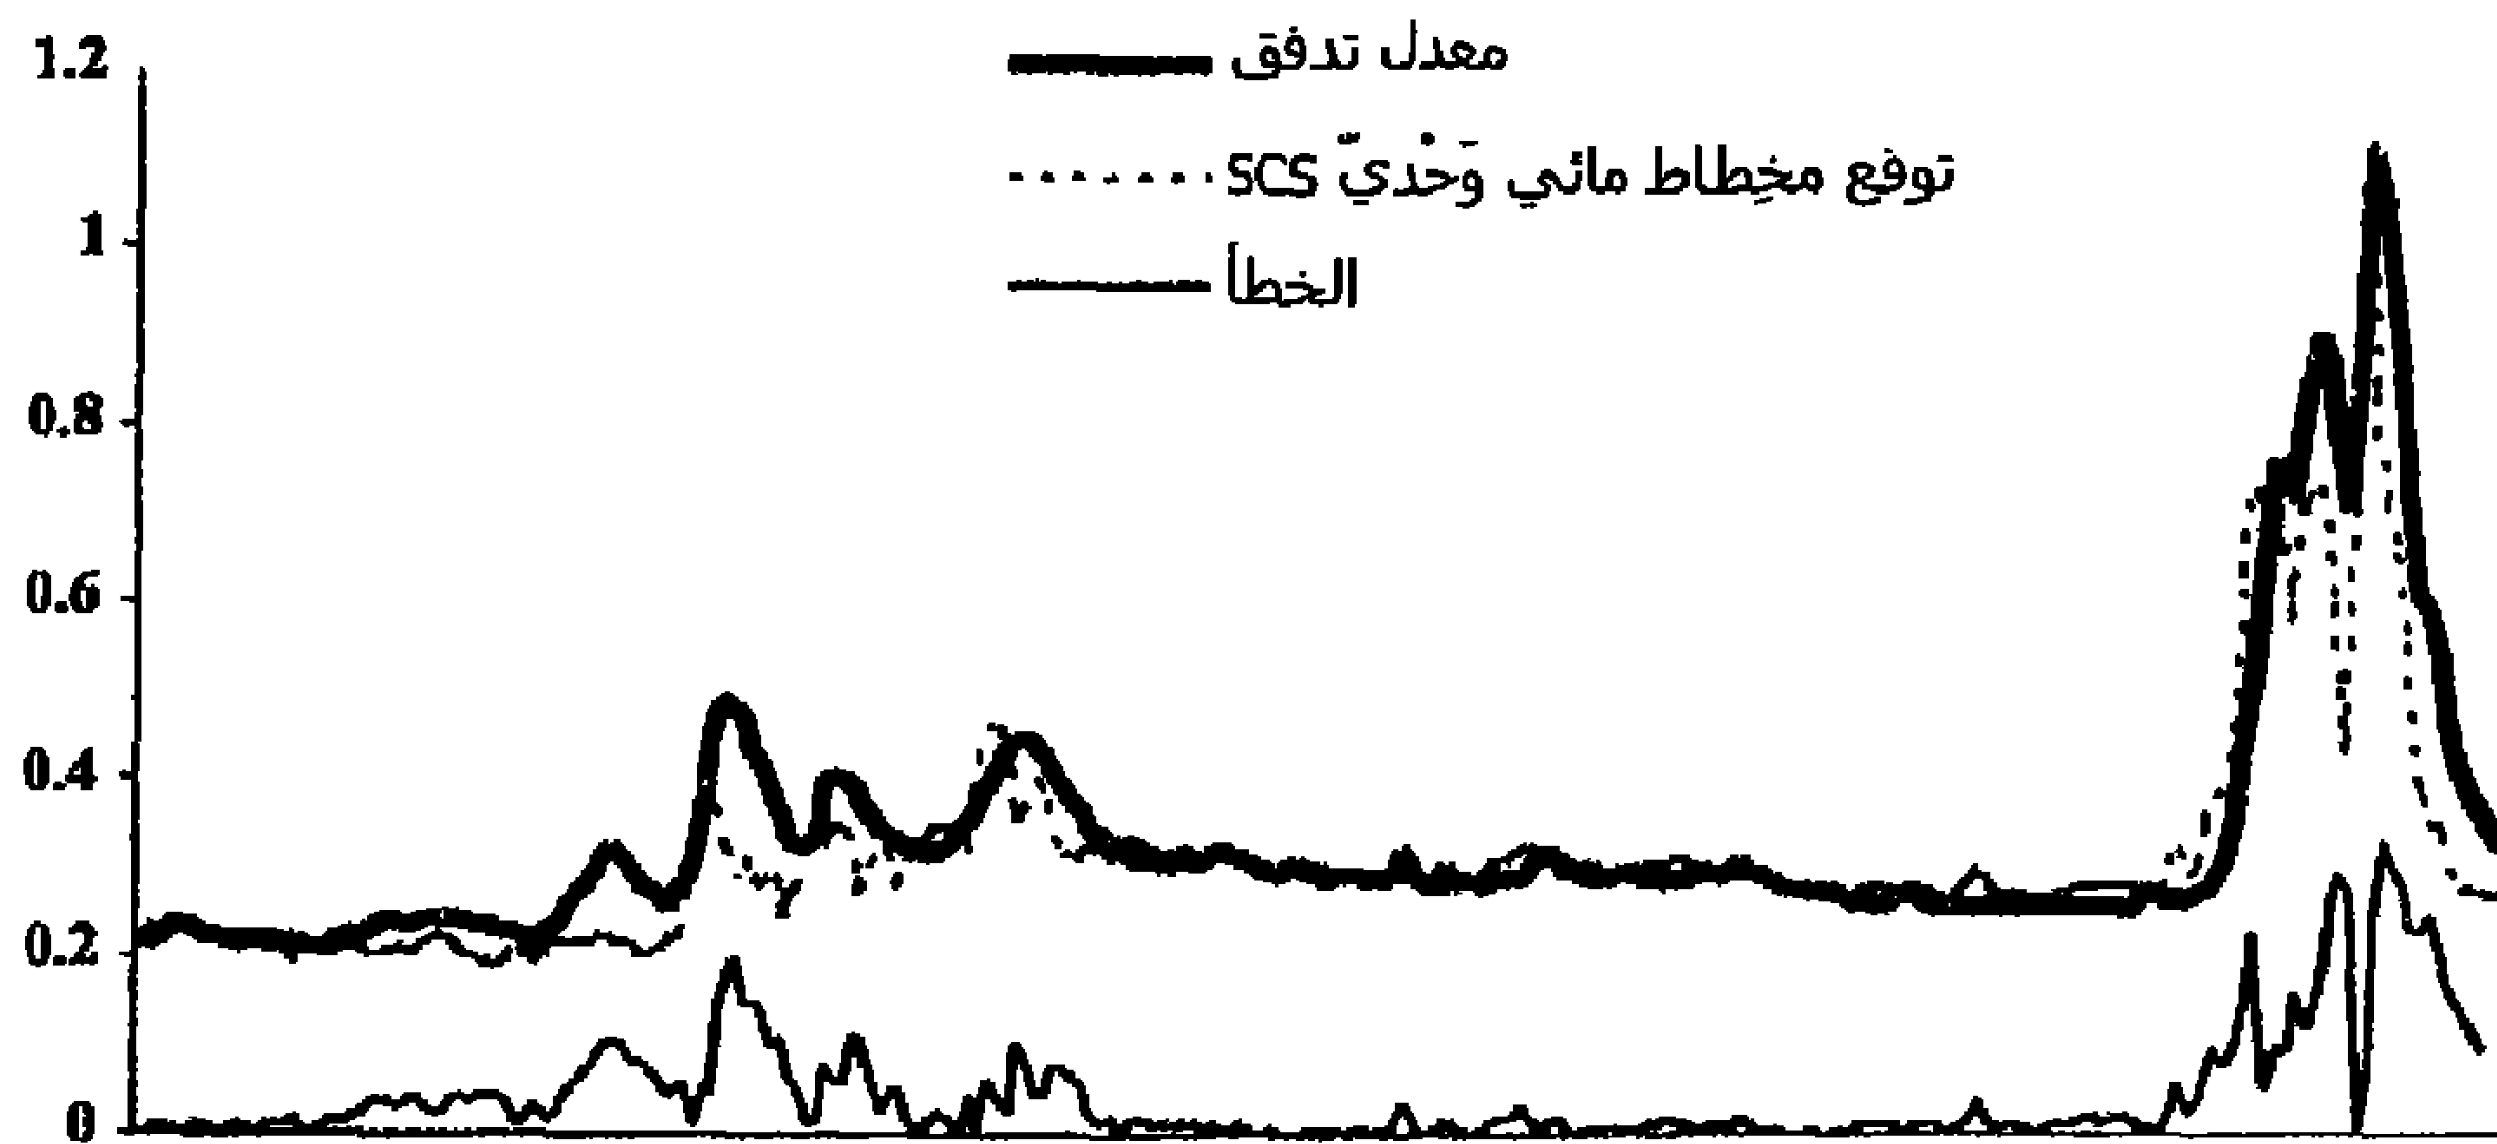
استجابات المخطاط المائي الوَحْديّ بالطرق

الاستجابة للنبضة الوحدوية المُنتجة بواسطة الطرق المختلفة يمكن مشاهدتها على (الشكل 18).

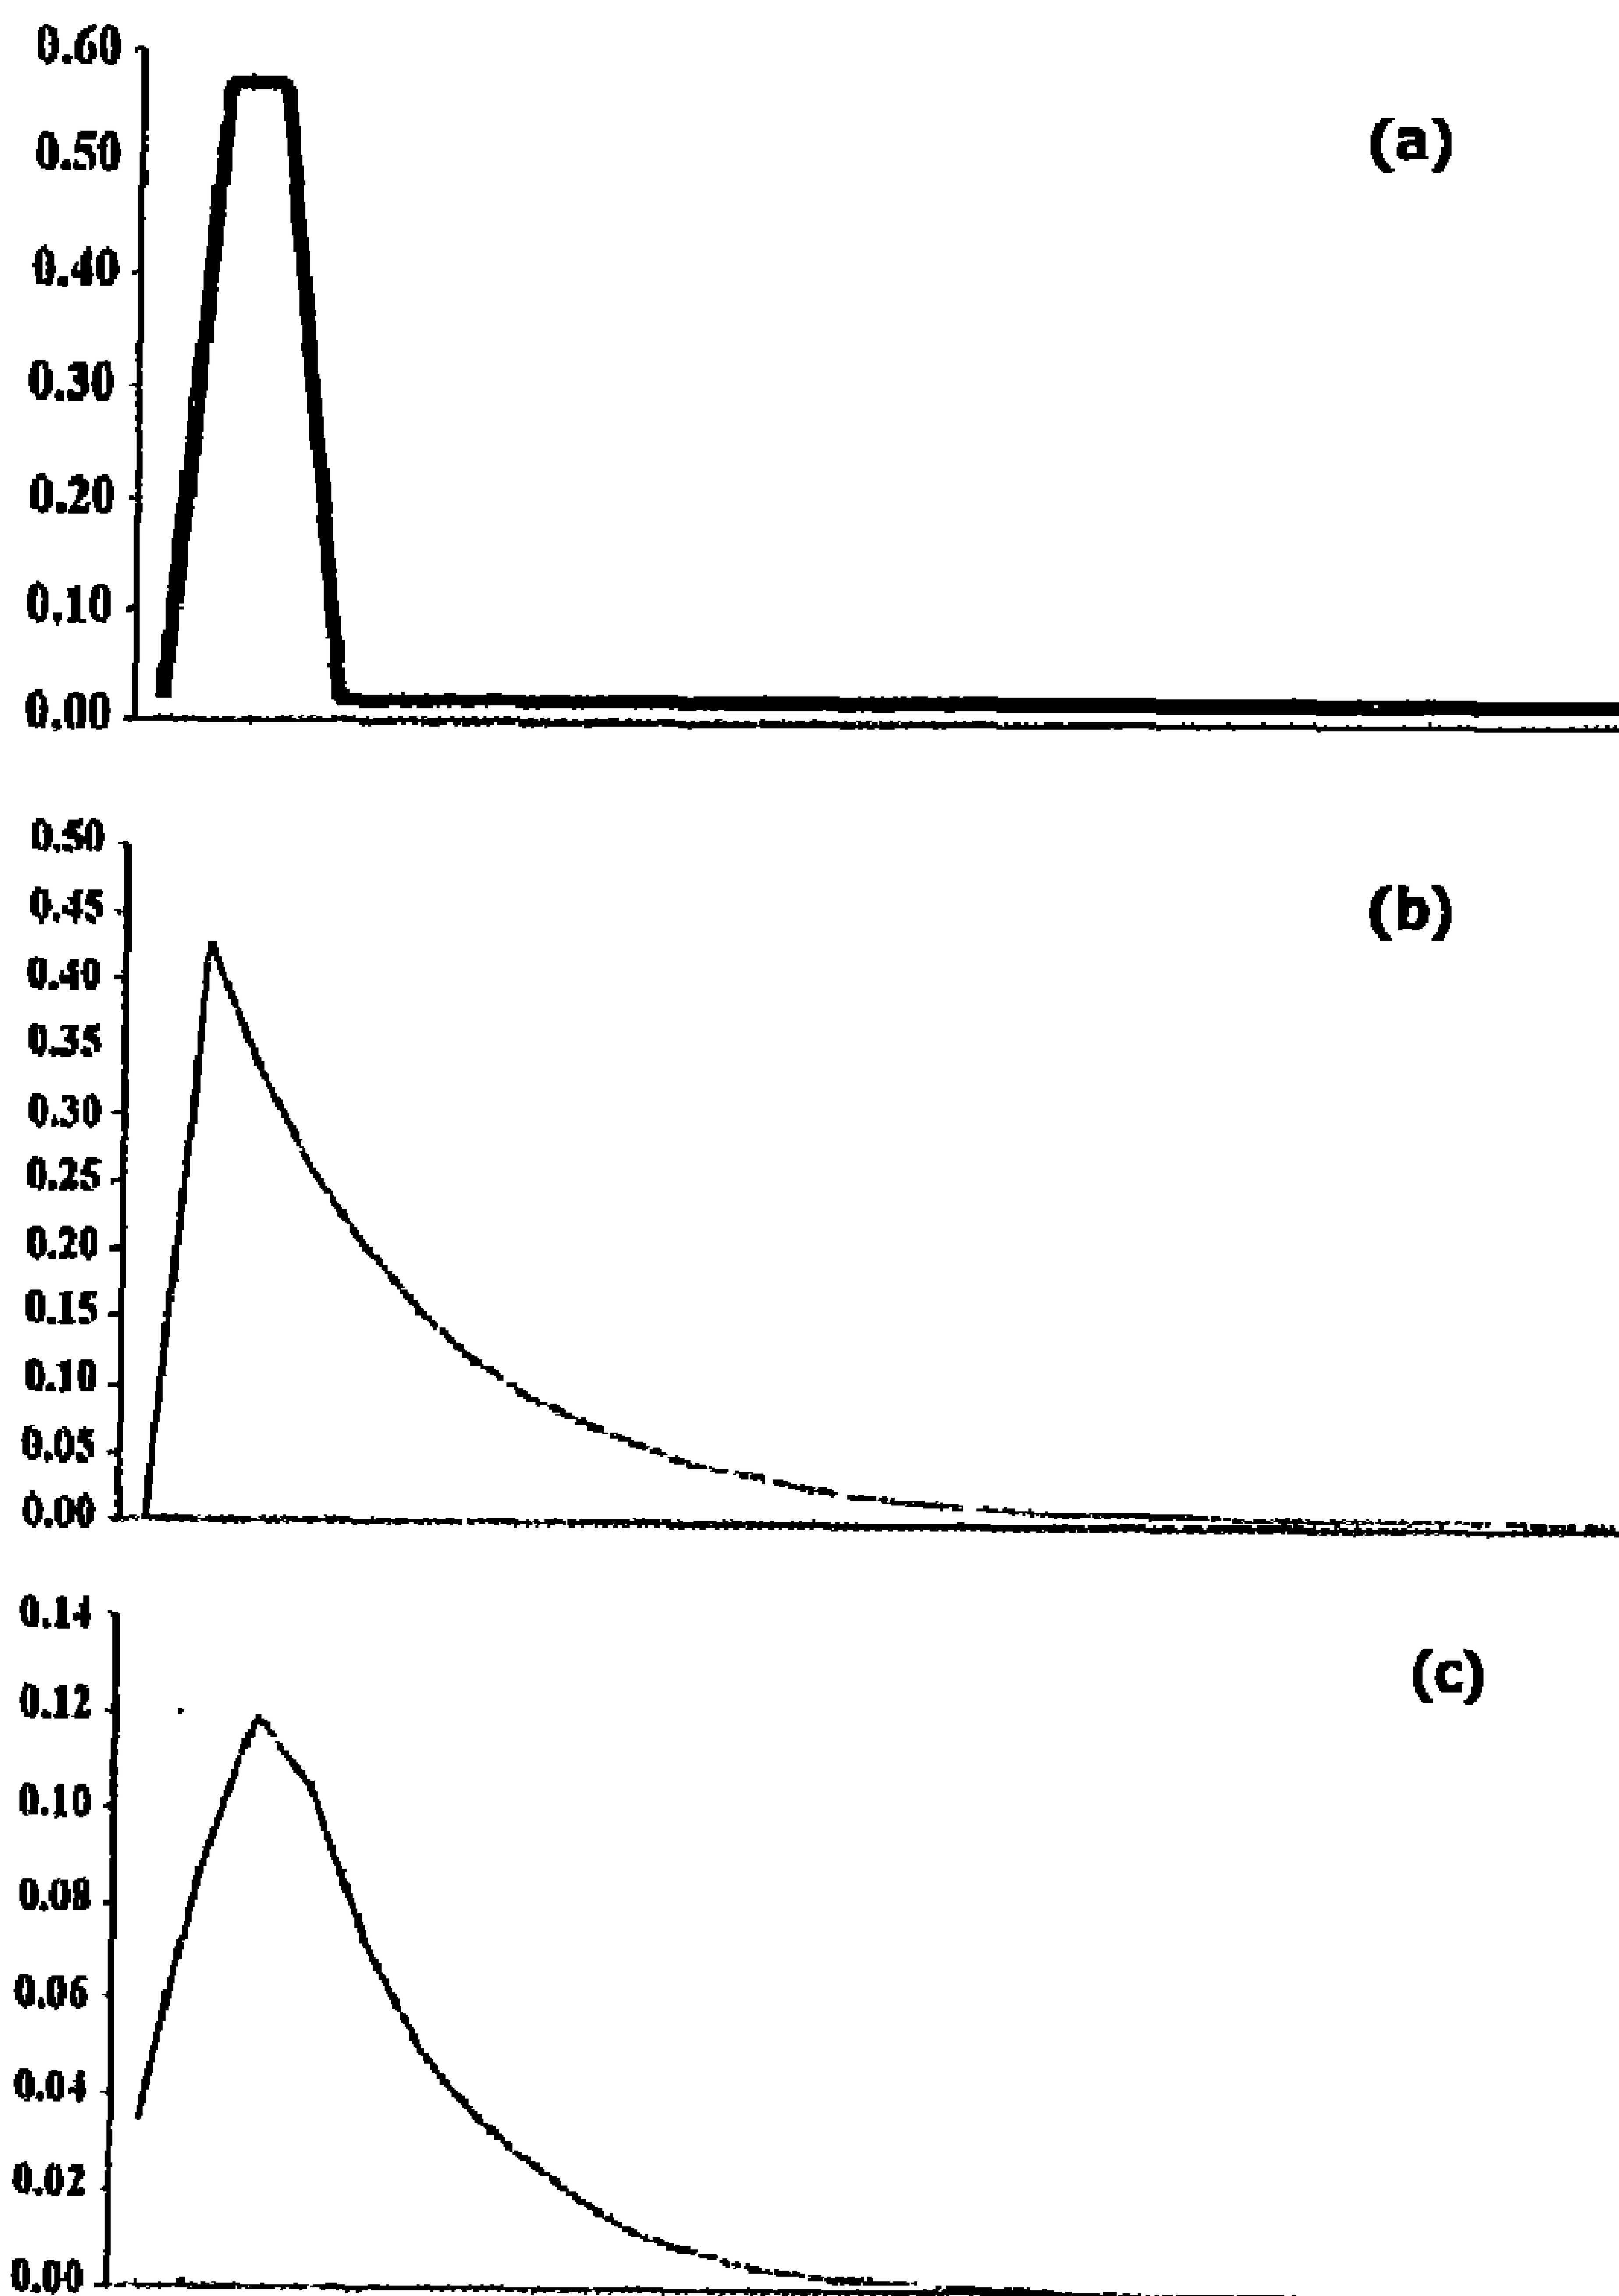
النتائج

يظهر (الجدول 1) مقارنة بين الإشارات الناتجة، وهي تبين أن الطريقة التطورية (GP) تعطي نتائج أفضل من الطريقة RANN وطريقة (SCS) التقليدية.

الشكل (17) *إشارة معدل التدفق ونتيجة توقع المخطاط المائي الوَحْديّ SCS (ملف اختبار).*



الشكل (18) *المخطاط المائي الوَحْديّ للطرق: a) تابع انحدار، b) RANN ، c) GP .*



الجدول (1) مقارنة بين الطريقة الأساسية (الانحدار)، طُرق الذكاء الصنعي (RANN, GP)، وطريقة المِخطاط المائي الوَحْديّ (SCS).

	انحدار	RANN	GP	SCS
ME	0.0776	0.0343	0.0052	0.0428
MSE	0.0169	0.0037	0.0001	0.0056

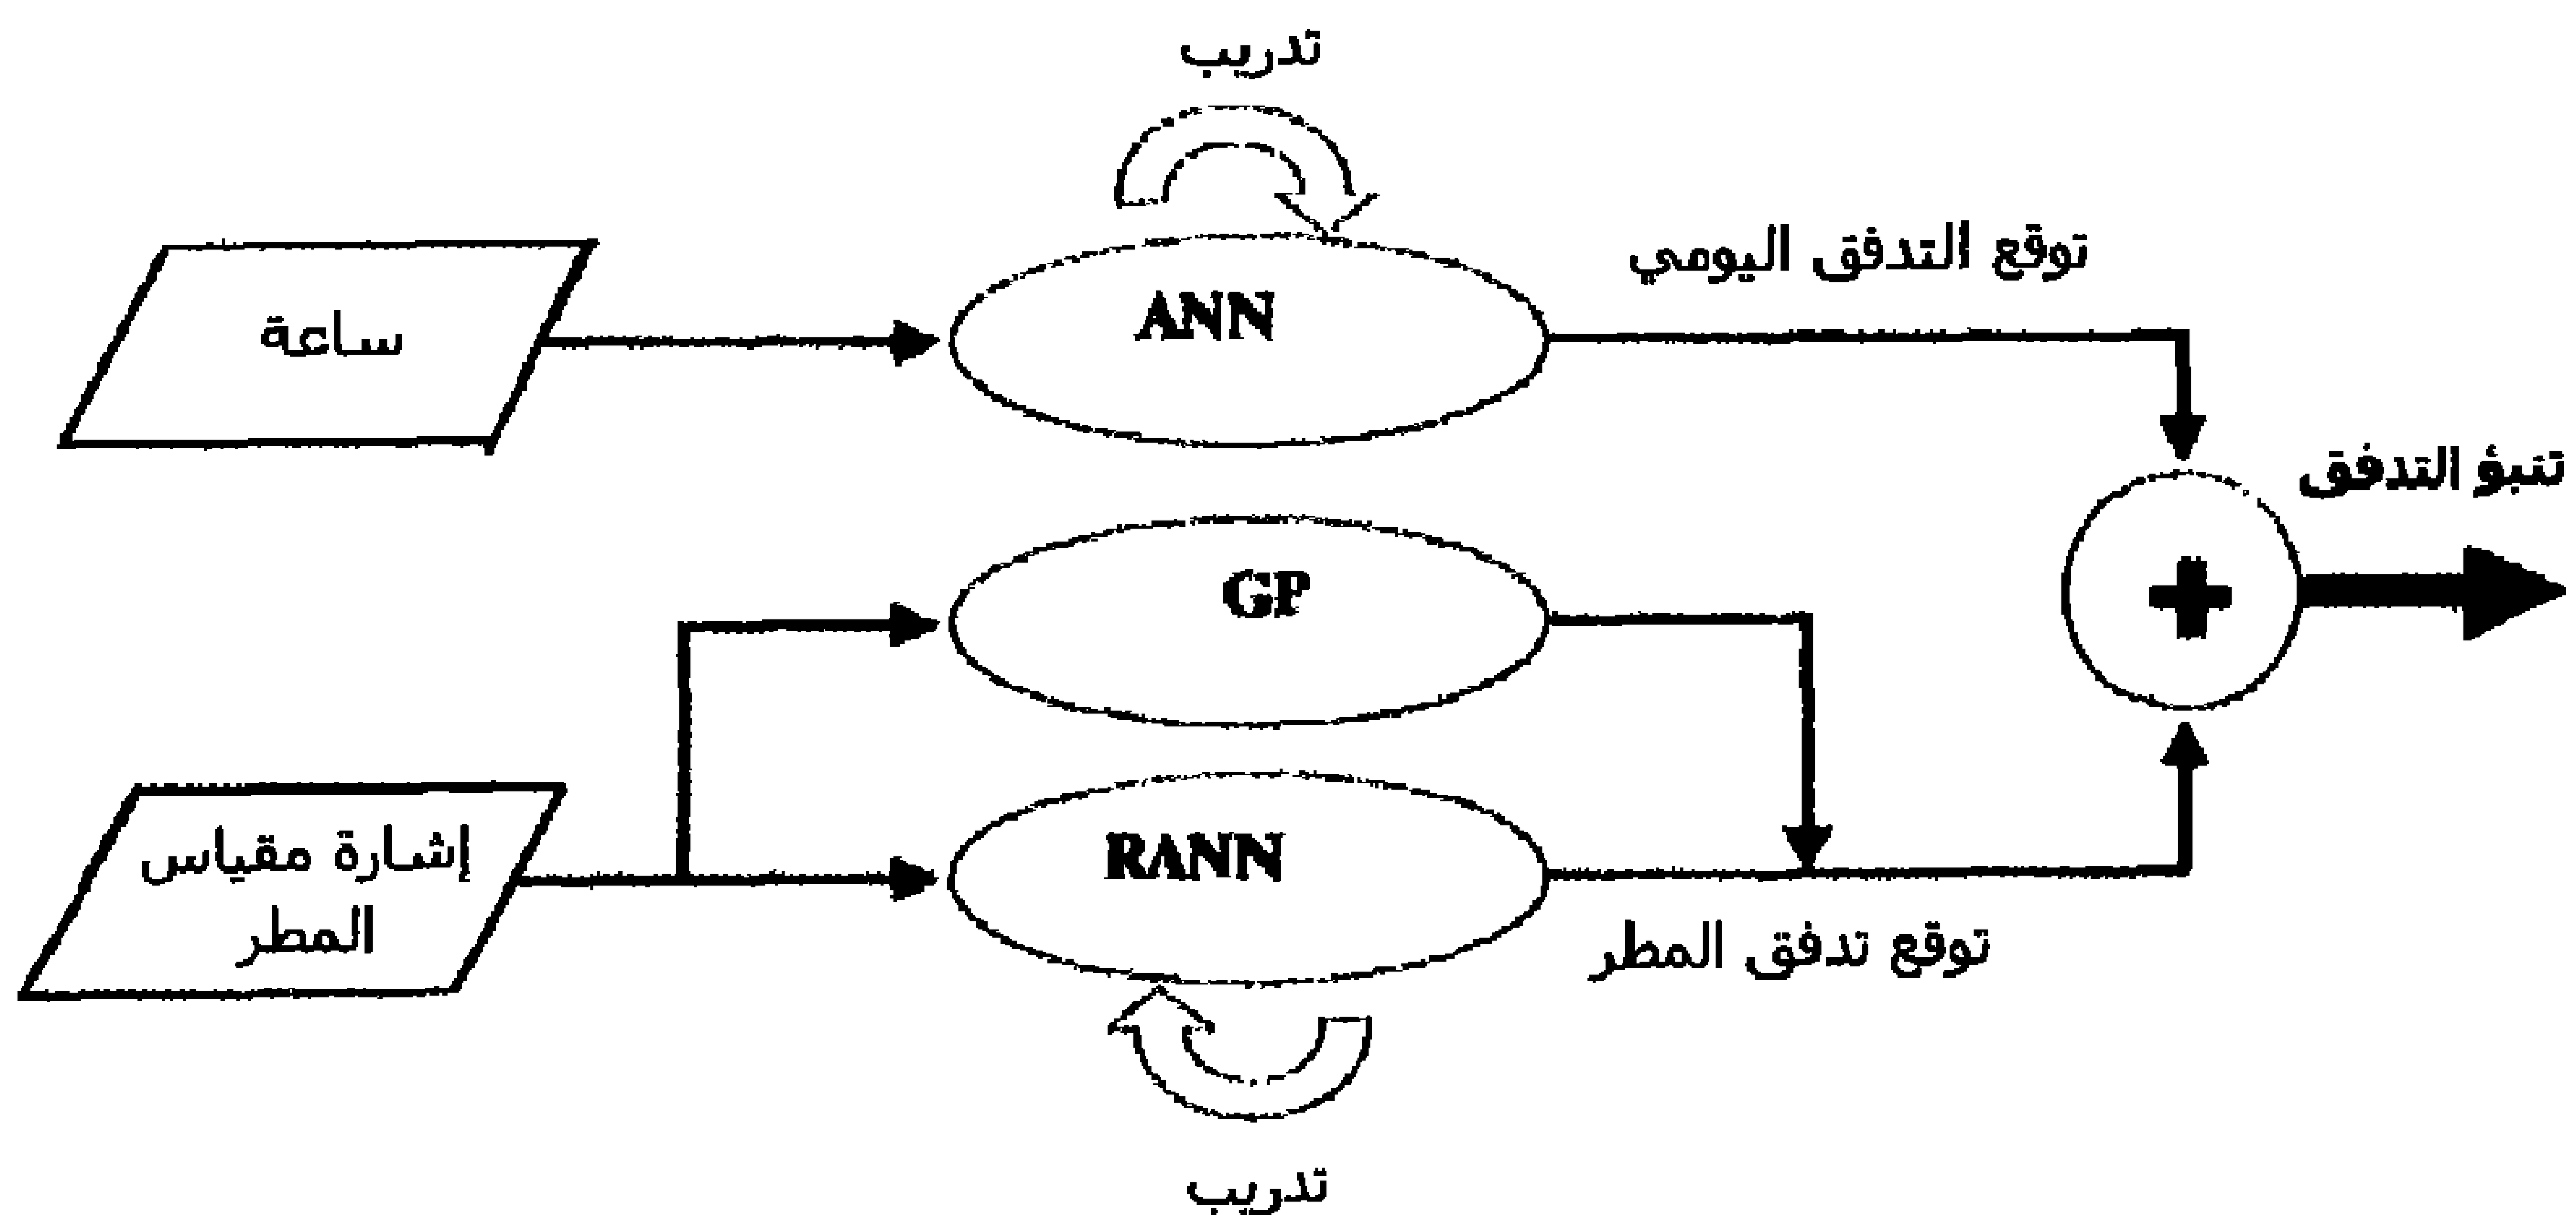
وصف النظام

يسمح النظام بولوج دخلين: منسوب مقياس المطر المُقاس والساعة في النقطتين المختلفين من هذه الإشارة اللتين تم قياسهما.

يتباين مدخل مقياس المطر RANN أو تعبير GP، ويجب الحصول بالتالي على توقع التدفق الناتج عن المطر. للحصول على التدفق الناجم فقط عن النشاط البشري في الماضي، استخلصنا هذه الإشارة من عينات التدفق الحقيقي. الآن، بإشارة النشاط البشري هذه يمكننا توقع عينة النشاط البشري التالية بواسطة ANN أمامية الانتشار.

وبإضافة فقط هاتين العينتين الناتجتين (توقع النشاط البشري بـ ANN، وتلك المتوقعة من المطر بـ RANN أو GP)، نحصل على إشارة الجريان السطحي العامة كما هو مبين في (الشكل 19).

***الشكل (19)** المخطط الوظيفي العام للنظام.*



الاتجاهات المستقبلية

ما لم يتم الحصول على نمذجة حوض صرف مدينة نموذجي، تُطبق التقنية المُقدمة لنمذجة أحواض صرف مدينة أخرى أقل نموذجيةً تتأثر بظواهر فيزيائية مختلفة مثل تشويش النفاذية السطحية، وتوزيع الماء عبر التربة التحتية، والتلوث ... وهلم جراً. كما ستُطبق التقنية أيضاً على أحواض الصرف الريفية، حيث لا يوجد هناك سلوك يومي نموذجي، بفرض أنه لا يوجد نشاط بشري مُتبق. لأن أحواض الصرف الريفية تمتلك نشاطاً بشرياً مُتبقياً مُخفضاً، فقد تكون طريقة النمذجة أكثر فعالية هي توقع مقادير الجريان السطحي.

على أية حال، تمتلك المناطق الريفية أيضاً خصائص سطحية، يمكن أن تكون حساسة أكثر للظواهر الطبيعية المعزولة (عواصف، جفاف، ..الخ)، وبالتالي انخفاض فعالية طريقة النمذجة لتوقع مقادير الجريان السطحي بدقة.

يكمن الهدف في تنفيذ نظام مستقل ذاتياً، يستطيع أن ينجز توقعات بزمن حقيقي، ويكون متكيفاً ذاتياً ومُصححاً لبارامتراته ديناميكياً عندما تحدث قياسات المطر.

وبالتالي، يمكن أن يتم الحصول على أنظمة إنذار قادرة على توقع خطر ظروف المطر لحوض الصرف.

الاستنتاجات

تثبت النتائج أن الإشارة المكتسبة مماثلة تماماً للإشارة الحقيقية، ولذا فإن الطريقة المستخدمة لا تؤتمت العملية فقط، بل تظهر أيضاً لتكون أفضل من تلك الطرق المستخدمة بشكل شائع في الهيدرولوجي.

تم الحصول على تعبير يربط التوقيت من اليوم بالتدفق الموافق من أجل نمذجة التدفق اليومي بواسطة تغذية عكسية بين قيم الدخل والخرج.

بعد عدة اختبارات، تم إظهار أن الطريقة التي أعطت أفضل النتائج، كانت تلك التي اُستخدمت فيها قوة GP للبحث عن أقطاب وأصفار النظام.

إن أهمية GP واضحة ليس فقط عند محاولة إيجاد العلاقات بين البارامترات فقط، وإنما أيضاً من أجل الحصول على تعابير بقيود لتطبيق تقنيات أخرى مثل البحث عن البارامترات في تصميم المرشح.

وكاستنتاج أخير، يمكن القول بأنه تم الحصول على النتائج الأفضل باستخدام نظام هجين، يدمج ANN أمامية الانتشار للتنبؤ بالتدفق اليومي مع GP للتنبؤ بالتدفق تبعاً لهطول المطر.

المراجع

Aafjes, J., Hendriks, L.J.W., Verberne, A.J.P., & Vingerhoeds, R.A. (1997). Voorspellen van het Drinkwaterverbruik met een Neuraal Network. H2O, 30(15), 484-487.

Atiya, A., El-Shoura, S., Shaheen, S., & El-Sherif, M. (1999). A comparison between neural-network forecasting techniques. Case study: River flow forecasting. IEEE Transactions on Neural Networks, 10, 402-409.

Darwin C. (1864). On the origin of species by means of natural selection or the preservation of favoured races in the struggle for life (6th ed.) (originally published in 1859). Cambridge, UK: Cambridge University Press.

Dorado, J., Rabuñal, J., Pazos, A., Rivero, D., Santos, A., & Puertas, J. (2003). Prediction and modelling of the rainfall-runoff transformation of a typical urban basin using ANN and GP. Journal of Applied Artificial Intelligence. 17, 329-343.

Dorado, J., Rabuñal, J., Puerlas, J., Santos, A., & Rivero, D. (2002, April 3-5). Prediction and modelling of the flow of a typical urban basin through genetic programming, Proceedings of the 5th European Congress on Genetic Programming, Ireland.

Fuchs, M. (1998). Crossover versus mutation: An empirical and theoretical case study. 3rd Annual Conference on Genetic Programming. Morgan-Kauffman.

Govindaraju, R.S., & Rao, A.R. (2000). Artificial neural networks in hydrology. Water Science and Technology Library (vol. 36). Kluwer Academic Publishers.

Huber, W.C., & Dickinson, R.E. (1992). Storm water management model. User's manual, Version 4. Athens, GA: Environmental.Protection Agency.

Johansson, E.M., Dowla, F.U., & Goodman, D.M. (1992). Backpropagation learning for multi-layer feed-forward neural networks using the conjugate gradient method. International Journal of Neural Systems, 2(4), 291-301.

Koza, J.R. (1992). Genetic programming. On the programming of computers by means of natural selection. Cambridge, MA: MIT Press.

Lippmann, R.P. (1987). An introduction to computing with neural nets. IEEE ASSP Magazine.

Loke, E.,Warnaar,E.A.,Jacobsen, P. ,Nelen, P., & do CeuAlmeida,M. (1997). Artificial neural networks as a tool in urban storm drainage. Water Science and Technology, 36(8-9), 101-109.

Luke, S., & Spector,L. (1998). A revised comparison of crossover and mutation in genetic programming. The 3rd Annual Conference on Genetic Programming. Morgan-Kauffman.

Montana, D.J. (1995). Strongly typed genetic programming. Evolutionary Computation, 3(2), 199-200.

Rabuñal, J.R., Dorado, J., Pazos, A., Pereira, J., & Rivero, D. (2004). A new approach to the extraction of ANN rules and to their generalization capacity through GP. Neural Computation,7(16), 1483-1523.

Schuize F., & Bouma N. (2000). Use of artificial neural networks in integrated water management. Proceedings MTM-III - Artificial Neural Networks in Water Management(pp. 333-342).

Sinak, P., Bundzel, M., Soka, M., Sztruhar, D., & Marsaiek, J. (1998). Urban runoff prediction by neural networks. In V. Babovic & L. C. Larsen (Eds.), Proceedings of Hydroinformatics '98 Conference, Balkema, Rotterdam (pp. 791 -796).

Vaes, G. (1999). The influence of rainfall and model simplification on combined sewer system design. Ph.D. thesis. Belgium: K.U. Leuven.

Viessmann, W., Lewis, G.L., & Knapp, J.W. (1989). Introduction to hydrology. Harper Collins.

Wisler, C.O., & Brater, E.F. (1959). Hydrology. New York: John Wiley & Sons.

Zhang, Q., & Stanley, S. (1997). Forecasting raw-water quality parameters for the North Saskatchewan River by neural network modeling. Water Research, 31(9), 2340-2350.

الفصل التاسع

التنبؤ بالتماسكية الخرسانية بواسطة استخدام الشبكات العصبونية الصنعية

ملخص

يعرض هذا الفصل مثالاً على تطبيق ANN في الهندسة المدنية، وبشكل محدد، تم تطبيقها للتنبؤ بتماسكية الخرسانة الطازجة من خلال النتائج التي يزودها اختبار الكزازة كطريقة بسيطة للسلوك الانسيابي (المرونة، واللزوجة، واللدونة) للخلطات. من الاختبارات المُنفذة سابقاً، تُضبط شبكة عصبونية صنعية (ANN) مُدرّبة بواسطة خوارزميات وراثية (GAs) على الحالة، وتمتلك القيمة المتغيرة للمخروط كخرج متغيرات متنوعة متعلقة بتركيب كل نوع من الخرسانة كدخل يعتمد المناقشة النهائية على النتائج وتطبيقها الممكن.

مقدمة

الخرسانة هي إحدى مواد البناء الأكثر استخداماً حالياً، بما أنها تؤمن مقاومة انضغاط عالية (مماثلة لما تؤمنه لصخرة)، ويمكن أن تهيأ في أشكال مختلفة خلال عملية إنتاجها. وهي مصنوعة من خليط من ماء واسمنت وخلْط دقيق (رمل من 0 إلى 4 مم)، وخلْط خشن (6 إلى 12 و 12 إلى 25 مم)، وفي بعض الحالات خلطات معدنية أخرى (إضافات)، أو خلطات كيميائية (مُضافات) بوظائف مختلفة.

الانسياب الخرساني وقابلية لتشكيل

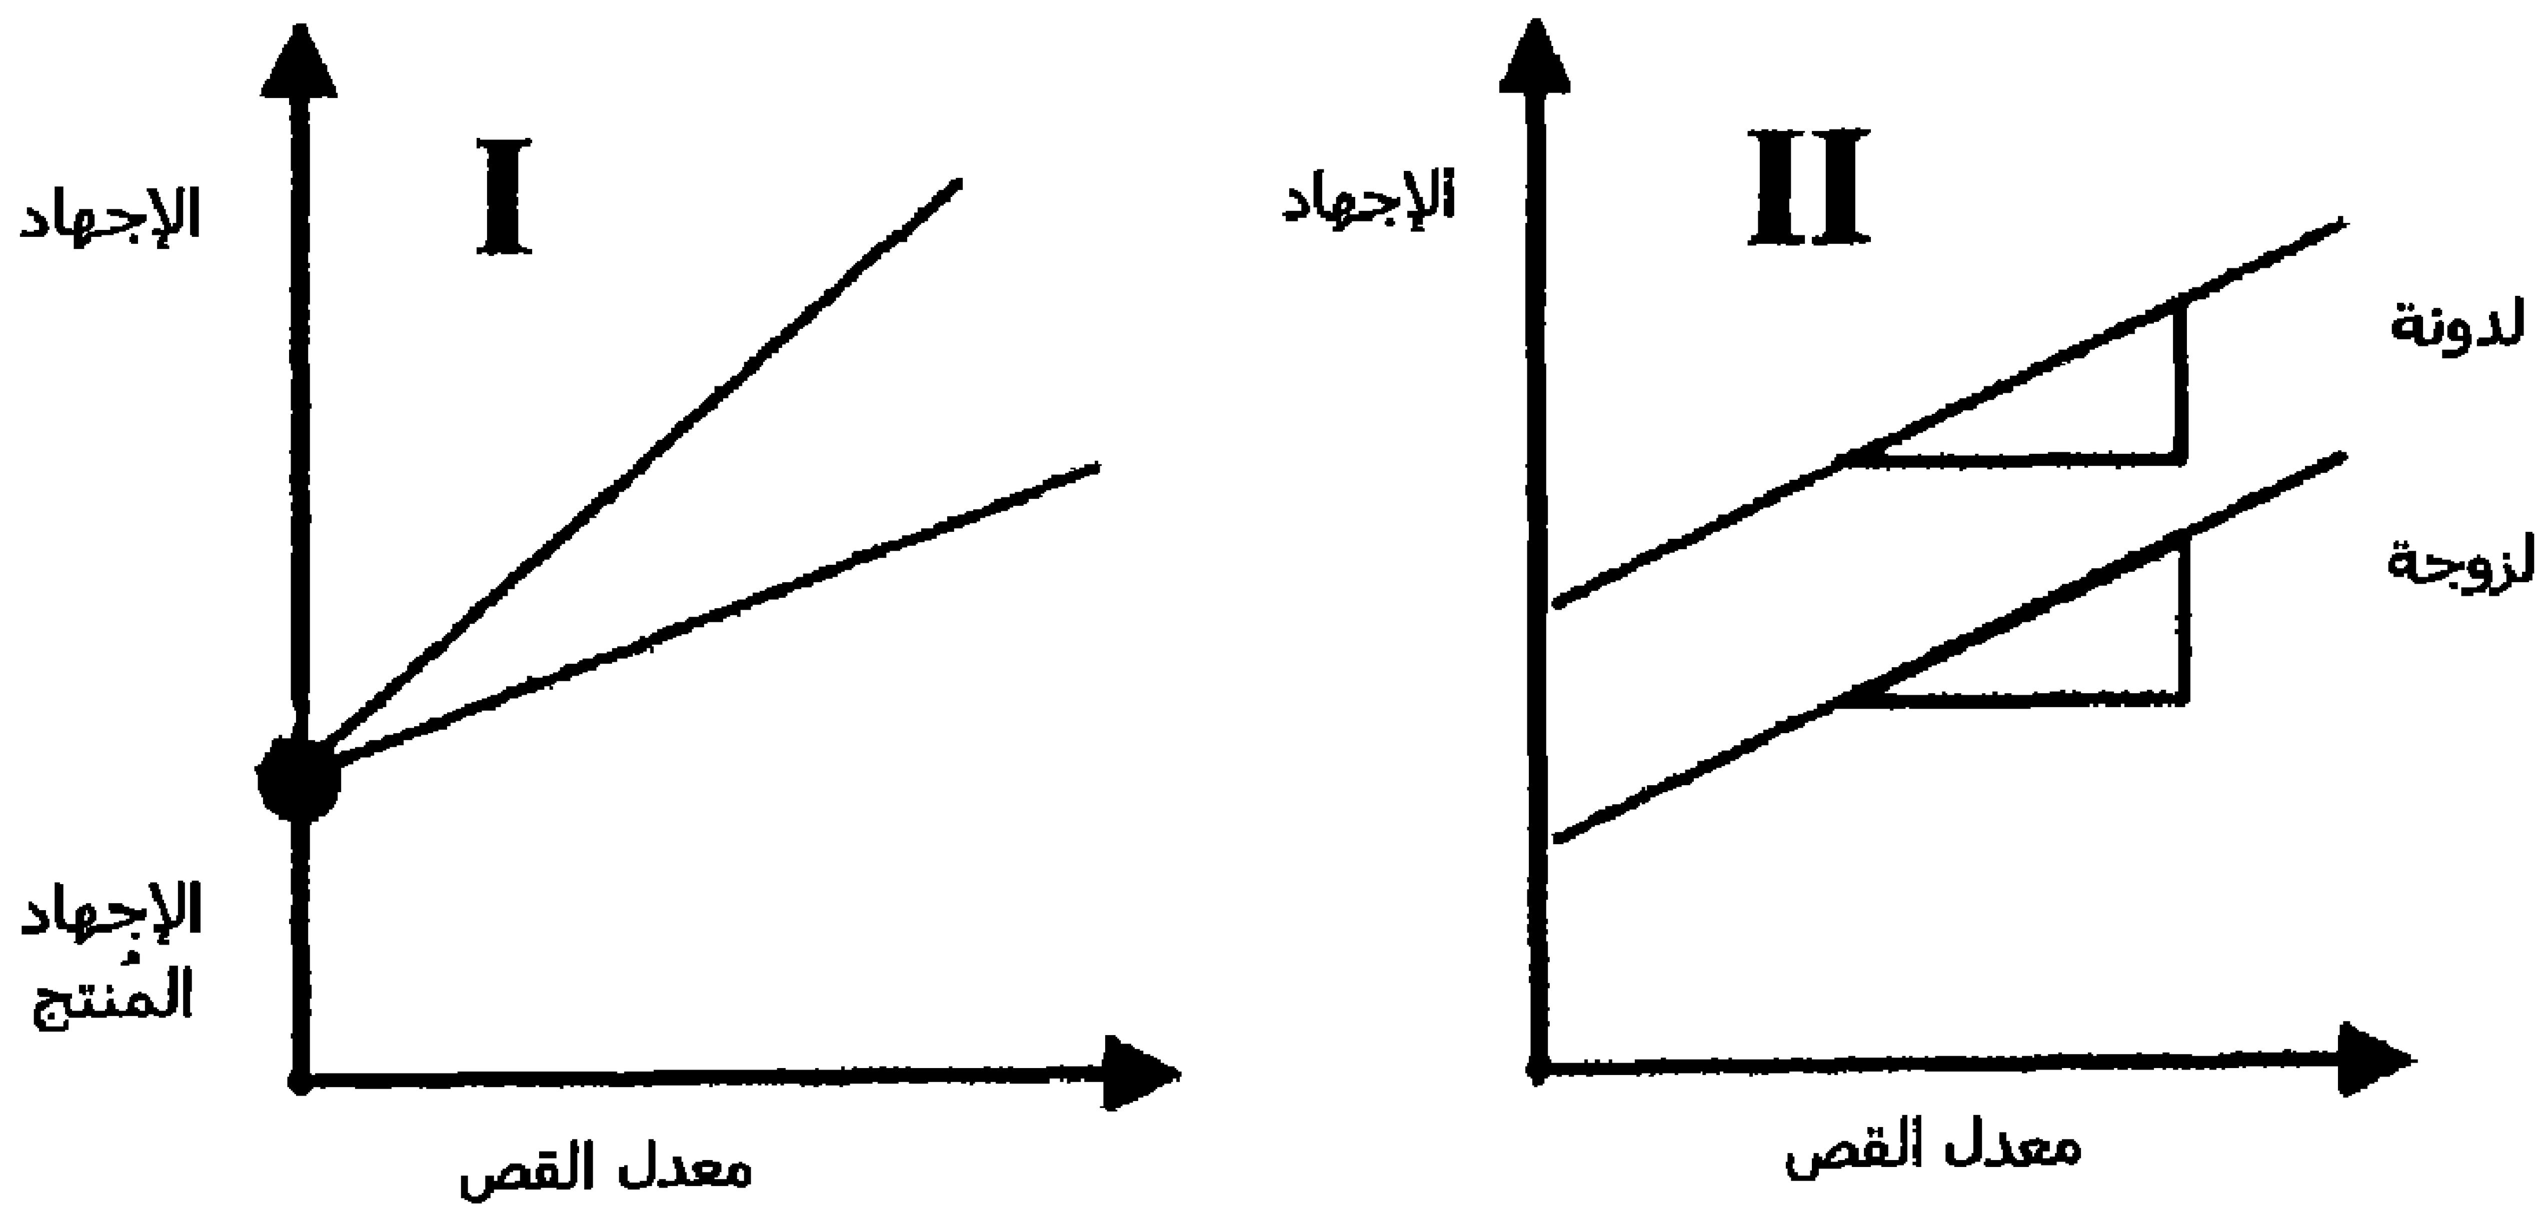
حُددّت المواصفات الرئيسية للخرسانة في مرحلتين مختلفين. المرحلة الأولى أثناء التصنيع التي تكون فيها المادة في حالة طرية، والمرحلة الثانية الموافقة لحالتها الصلبة. تبدو الخرسانة في المرحلة الأولى مشابهة لمادة سائلة، ويمكن أن تهيأ في أي شكل. هذه المواصفة مرتبطة بقابلية تشكيلها، ويكون قياسها ضروري لأن قدره الخرسانة للتهيؤ في شكل آخر سيعتمد عليها.

تسمح أيضاً قابلية التشكيل المناسبة بإمكانية ضغط الخرسانة، اللازم لإخلاء المحتوى الهوائي المندمج أثناء عمليات الإنتاج والوضع.

تعتمد قابلية التشكيل (أيضاً سهولة الوضع، السلاسة، والتماسكية) على المواصفات الانسيابية للسائل، التي تكون عادة مرتبطة بنموذج Bingham (Tattersall. 1991). ويجب أن تُحدد لضمان قدرة الخرسانة على أن تكون موضوعة. وفقاً لهذا النظرية، يمكن أن تُوصف الخرسانة الطرية ببارامترين أساسيين: لزوجتها اللدنة (زيادة إجهاد القص القص على الإجهاد المُنتج مُقسم على نسبة القص)، وإجهادها المُنتج (إجهاد القص الحرج إلى نقطة ما، التي ما إن يتم تجاوز الجهد المنتج للدونة اللزجة تتدفق المادة مثل السائل). غالبية الاختبارات واسعة الاستخدام غير مرضية من جهة أنها تقيس بارامتراً واحداً فقط، لا يصف الانسياب الخرساني بالكامل. يظهر (الشكل 1) كيف يمكن لخرسانتين أن تمتلكا بارامتراً واحداً متماثلاً وبارامتراً آخر مختلفاً جداً.

قد تكون هاتان الخرسانتان مختلفتين جداً في سلوك تدفقهما. وبالتالي، فمن المهم استخدام اختبار يصف السلوك الخرساني بقياس كلا المعاملين على الأقل.

الشكل (1) *نموذج Bingham لاثنين من الخلائط الخرسانية بسلوك مختلف.*



قياس إمكانية التشكيل للخرسانة

إن طرق تحديد إمكانية التشكيل هي عادةً طرق غير مباشرة. الطرق الشائعة هي معدل التدفق، وعامل الرخم (التدميج)، والكزازة (كونها الأقدم) (Abrams, 1922). هذه الطريقة الأقدم هي الأكثر استخداماً لبساطتها.

طُوّرت مقاييس لزوجة ومقاييس انسيابية أخرى لضبط البارامترات لنموذج Bingham على الرغم من أن استخدامها في البناء محدود جداً.

إن الاختبار بسيط جداً ورخيص، ويستخدم في البناء لتحديد ما إذا كانت الخرسانة مقبولة قبل وضعها. إن طريقة الاختبار هي طريقة قياسية على نحو واسع في كافة أنحاء العالم متضمنةً في ASTMC143 في الولايات المتحدة، وEN12350-2 في أوربا (Kochler & Fower, 2003).

يتألف الجهاز من قالب معدني على شكل مخروط مقطوع، قطر قاعدته الكبرى يساوي 20 سم، وقطر قاعدته الصغرى هو 10 سم، وارتفاعه الكلي 30 سم. القالب محشو بالخرسانة في ثلاث طبقات متساوية الحجم. كل طبقة مُدمجة بـــ 25 ضربة من قضيب حشوة. عندما تنتهي عملية الحشو، يُنزع المخروط، ويُقاس الارتفاع النهائي لكتلة الخرسانة. يظهر (الشكل 2) عملية الاختبار.

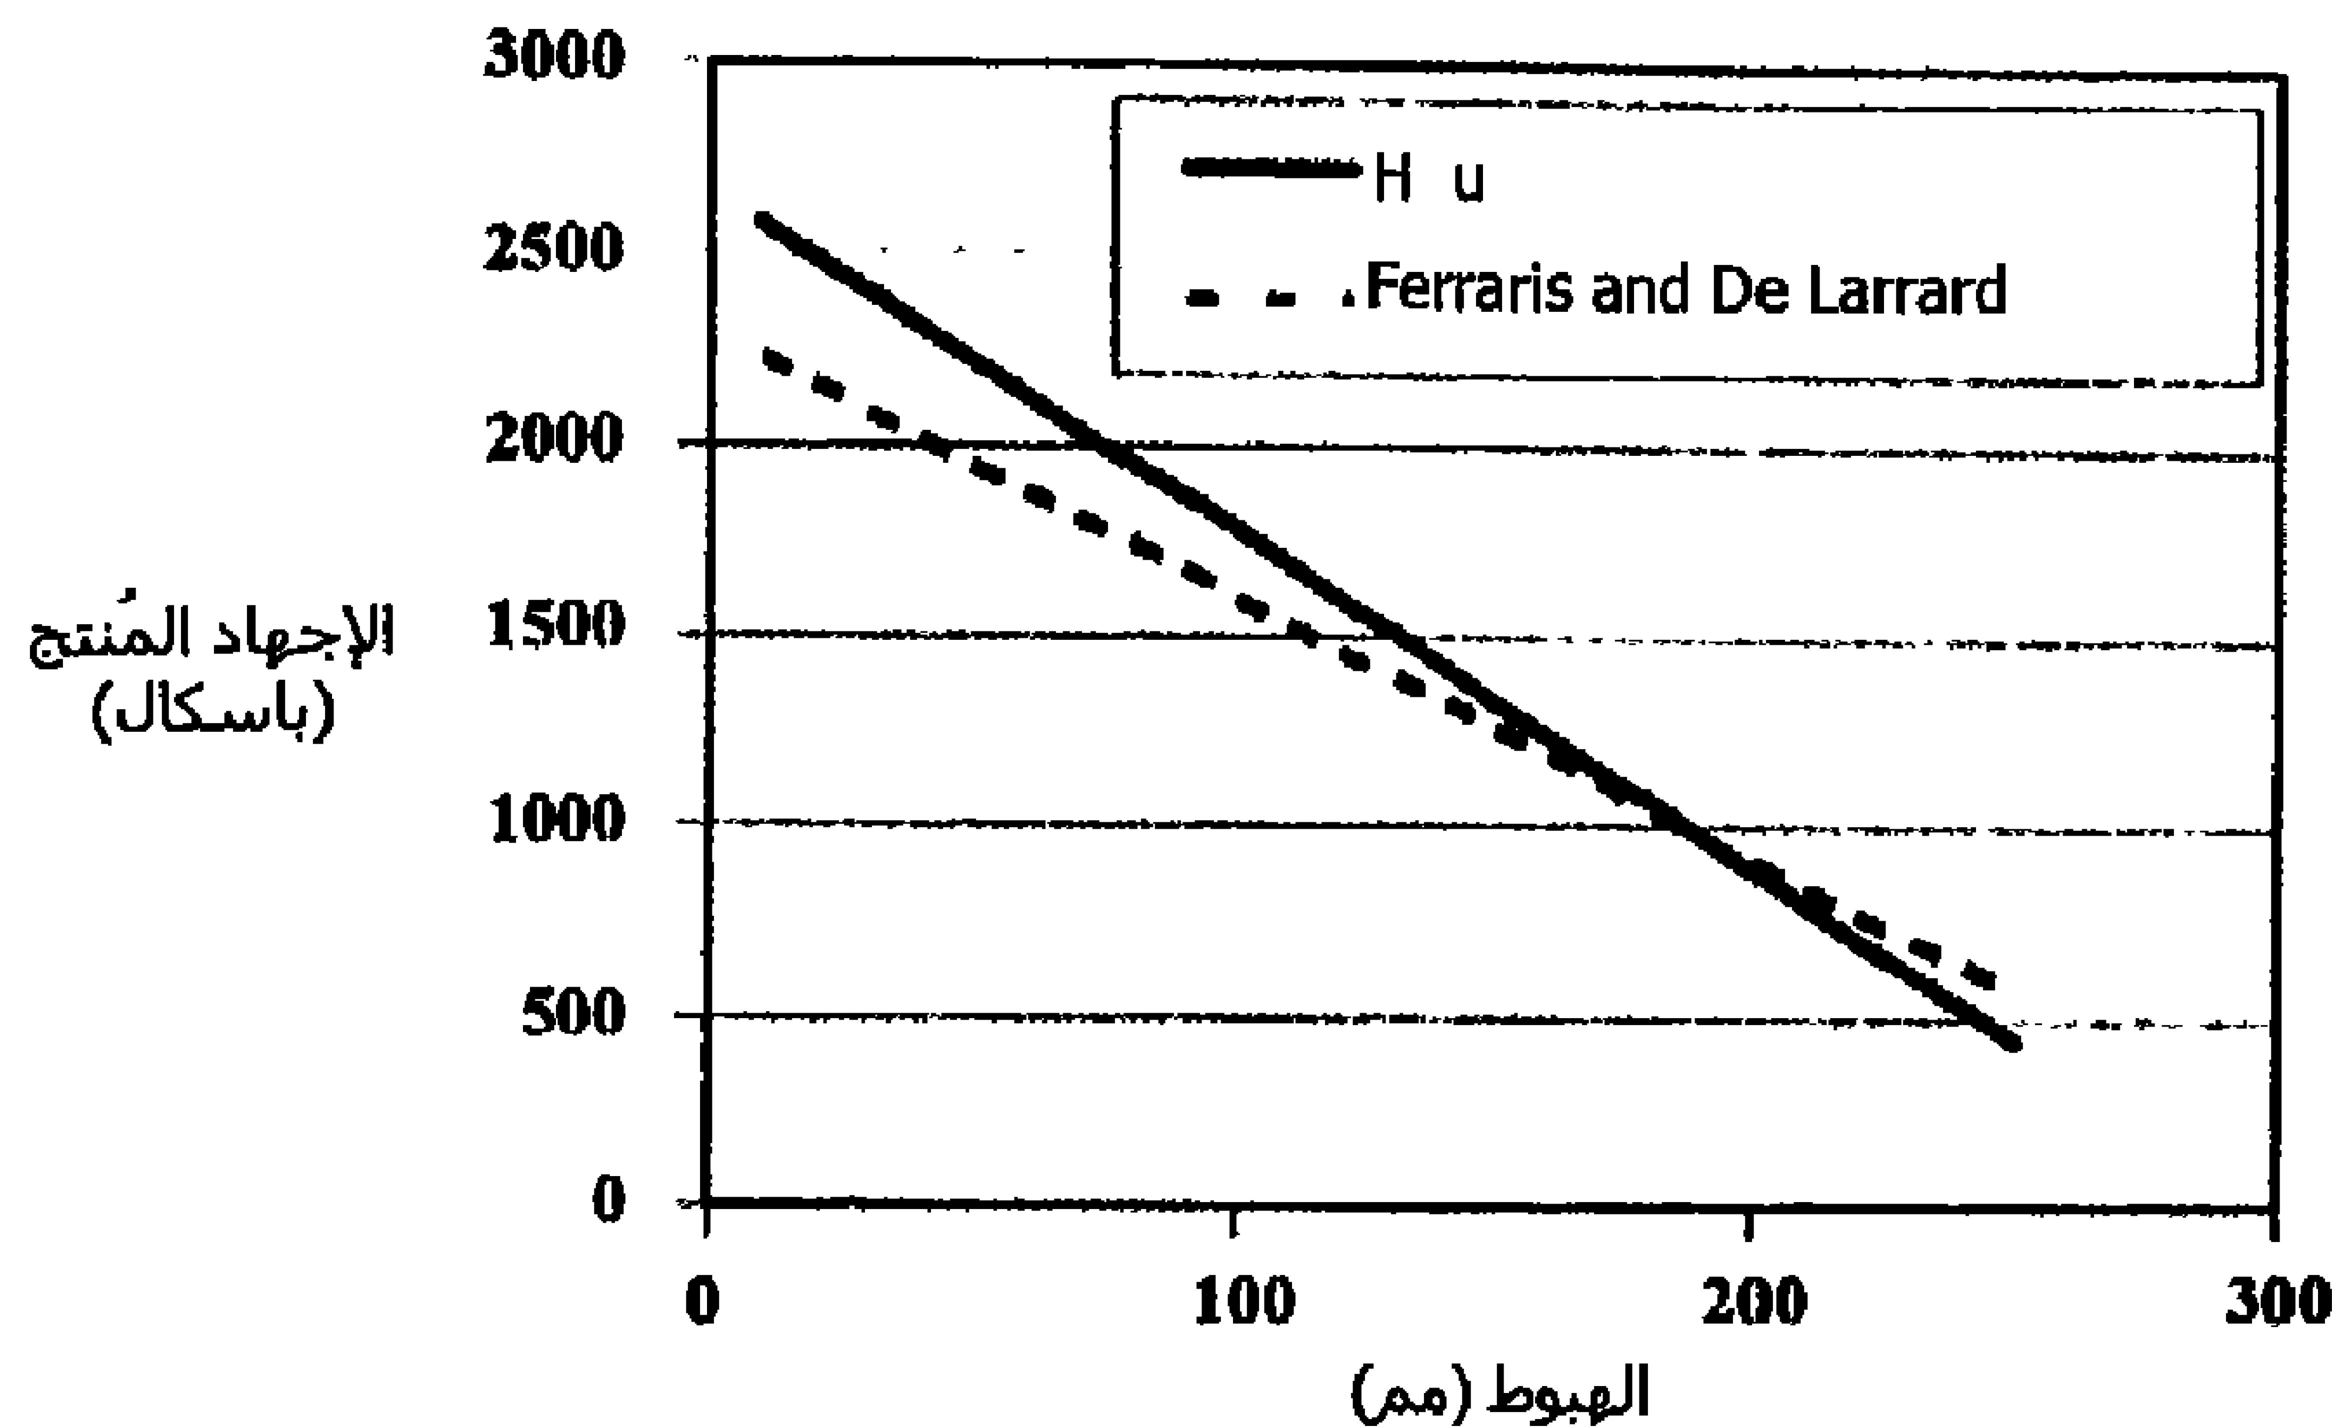
الشكل (2) *عملية الاختبار باستخدام مخروط Abrams.*



يتكون الإجهاد في هذا الاختبار من وزن الخرسانة لكل واحدة مساحة. يتأثر الهبوط (الكزازة) بكل من الإجهاد المُنتج واللزوجة اللدنة. على أية حال، في معظم الحالات يكون تأثير اللزوجة اللدنة على الهبوط مهملاً. ستهبط الخرسانة أو تتحرك فقط، إذا تم تجاوز الإجهاد المُنتج، وسيتوقف عندما يكون الإجهاد (أو وزن الخرسانة/المساحة) أقل من الإجهاد المُنتج.

طُورت معادلات حساب الإجهاد المُنتج من الهبوط باستخدام مقاييس انسيابية أو طرق عددية لحسابها. على الرغم من التبعية الشديدة للطريقة التجريبية المستخدمة، فإن المعادلة المنشورة من قبل العا لم Huet et al. (1996) قد أُكدّت وعُدّلت من قبل العالمين Ferraris وDe Larrard (1998). (يظهر الشكل 3) العلاقة التي تزودها كلا المعادلتين بين الإجهاد المنتج بالباسكال (pa) والهبوط بالميللي متر (mm).

الشكل (3) العلاقات المدروسة بين الهبوط والإجهاد المُنتج.



يصنف الكود الإسباني EHE (1999) الخرسانات بهذه الطريقة تبعاً لقابلية تشكيلها (المصطلح المستخدم هو التماسكية). وهو يسمح بتفاوت صغير في نتائج اختبار الكزازة الناتج في القيم التالية.

- **جاف**: الهبوط بين 0 و2 سم (الاختبار بين 0 و2 سم)
- **لدن**: الهبوط بين 3 و5 سم (الاختبار بين 2 و6 سم)
- **رخو**: الهبوط بين 6 و9 سم (الاختبار بين 5 و10 سم)
- **سائل**: الهبوط أكبر من 10 سم (الاختبار أكبر من 8 سم)

تمتلك قيمة التماسكية لخرسانة ما أهمية كبيرة بمعزل عن القضايا التقنية المذكورة سابقاً. وتصبح بارامتراً أساسياً عندما يتم استلام الخرسانة في أي موقع بناء بسبب المعاني الضمنية التي تم توضيحها. تُقبل المادة إذا كانت الخرسانة ضمن الحدود المسموح بها (قيم الهبوط)، وإلا تُرفض إذا لم تكن كذلك.

العوامل التي تأثر على قابلية التشكيل

إحدى أهم العوامل التي تؤثر على قابلية التشكيل هي كمية الماء، وبشكل خاص نسبة الماء/الاسمنت. يجب أن تكون هذه النسبة منخفضة لضمان مقاومة انضغاط عالية ومتانة، وهذه النسبة المنخفضة غير مواءمة مع قابلية التشكيل للخليط . وهذا هو السبب في كون الخلطات

الخافضة للماء (مُلَدنات ممتازة معروفة لكل من مواصفات مانع التدمّج خاصتهم، ولأن بإمكانهم معادلة الشحنات الكهربائية الموجودة على سطح جزئيات الاسمنت الذي يقلل ميلهم للتلبّد) عادةً متضمنة في الخلطات. على أية حال، تؤثر عوامل أخرى عديدة بشكل مباشر على قابلية التشكيل، وهي:

- نوعية وكمية الاسمنت.
- كمية وشكل ورطوبة الرُكام (رمل وحصى الخرسانة)
- تسلسل إدخال المواد في آلة الخلط.
- نوع آلة الخلط وزمن الخلط.
- الزمن المنقضي من لحظة إنتاج الخليط حتى قياس قابلية التشكيل.
- الظروف البيئية (درجة الحرارة والرطوبة الجوية).

من الممكن ملاحظة، بأنه في المتغيرات الأساسية، التي من الضروري أن تكون مفهومة، تكون قابلية تشكيل الخرسانة معلومة. كما يلاحظ أيضاً، أن النماذج النظرية قريبة جداً من السلوك الحقيقي، ولكنها تتطلب أنظمة صعبة غير مستخدمة حالياً في البناء. أخيراً، توجد اختبارات عديدة تميز كل بارامتر متضمن في قابلية التشكيل تقريباً. لذا، يبدو بأن شروط تحديد قابلية التشكيل للخرسانة مناسبة للاستخدام في تقنيات معتمدة على الذكاء الصنعي، وبشكل خاص في الشبكات العصبونية الصنعية (ANNs).

بناء ANN

المعطيات الابتدائية

تم الحصول على المعطيات التالية من الاختبارات المنفذة في "مركز الإبداع التقني في البناء والهندسة المدنية (CITEEC)" في جامعة A Coruña (Gonzalez Fonteboa, 2002). في تلك الاختبارات، صُممت خلطات اسمنتية لإبقاء بعض البارامترات ثابتة:

- درجة الحرارة (20°C) والرطوبة الجوية (60%).
- نسبة الماء إلى الاسمنت ثابتة في كافة الاختبارات عند القيمة 0.55.
- توضع نسبة الخَلْط الدقيق إلى الخِلْط الخشن (بالوزن)، بشكل ثابت بين 0.48 و0.51.

- نسبة الركام إلى الاسمنت ثابتة عند 6.08.
- نوع المواد المستخدمة (باستثناء نقاوة الاسمنت، على الرغم من أنه تم الإبقاء على الاسمنت بدون تغيير في كافة الاختبارات).
- زمن قياس قابلية التشكيل في كافة الحالات بعد عملية الخلط مباشرة.
- تسلسل وزمن الخلط.
- نوع آلة الخلط.

كانت المتغيرات المدروسة هي التالية:

- الخِلْط الدقيق (FA) من 0 إلى 6 مم: من حجر الكلس (حجز جيري).
- الخِلْط الخشن (CA) من 6 إلى 12 مم: من الكوارتز كنتيجة للهَصر.
- الخلط الخشن (CA) من 12 إلى 25 مم: من الكوارتز كنتيجة للهَصر.
- المحتوى المائي للركامات (بسبب رطوبتها).
- اسمنت: PortLand CEMI-42.5R
- وزن الماء الحر: الماء المُضاف خلال عملية الخلط.
- المُلدّن الممتاز: مخفض ماء ذو مجال عالي (HRWR)، وقد استخدمت صولفانيت النفتالين.
- وزن الخليط: المجموع الكلي لكتل المواد المستخدمة في الخليط.
- نقاوة الاسمنت: المُقاسة ببارامتر بلين السطحي، وقد تم استخدام درجتي نقاوة فقط.
- حالة الخلاّطة: استخدمت الخلاّطة عدة مرات متتالية. بعد كل عملية خلط، يتم تفريغ الخلاّطة – على أية حال – تبقى الرطوبة وبقايا الخلط لخليط تالي، وهذا الأمر لا يحدث في عملية الخلط الأولى، وبالتالي هناك فقط حالتين محتملتين.

وفقاً (للجدول 1)، فإن 69 خليط تم إتمامه. في هذا الجدول، يمكن ملاحظة القيم الحدية المنسوبة إلى المتغيرات المدروسة. أخيراً، أخذ بالحسبان المجال المُعتبر لبناء الـــ (Rodriguez, 2002).

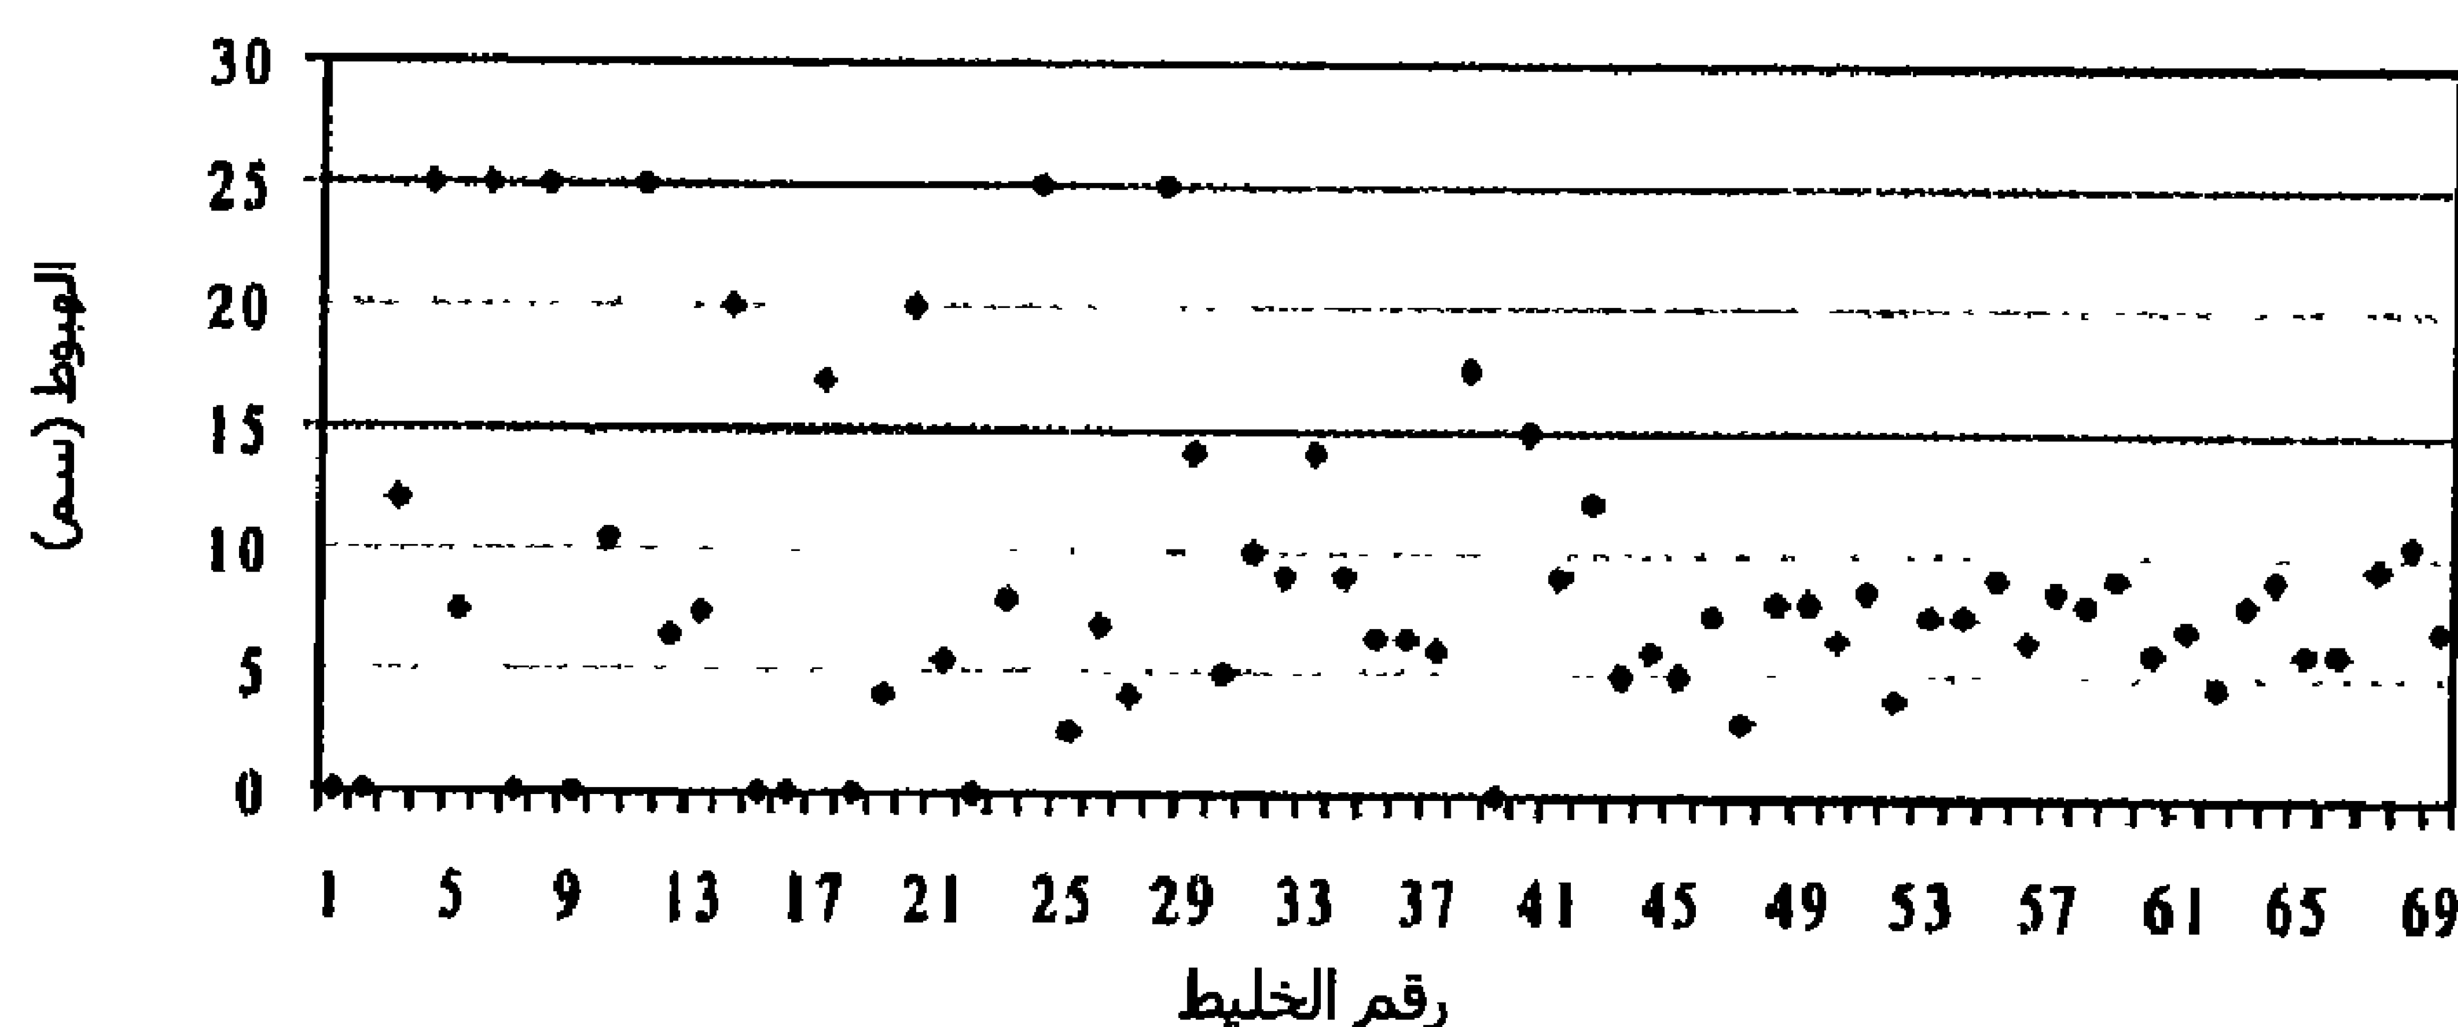
تظهر النتائج لـــ 69 خليط على (الشكل 4). كما يلاحظ، يأخذ الهبوط قيماً بين 0 سم (الخليط رقم 1، 2، 7، 9، 15، 16، 18، 22، 39)، و25سم (الخليط رقم 4، 6، 8، 11، 24، 28).

قُرر أخذ 60 خليطاً لمرحلة التدريب، وإبقاء التسعة البقية من أجل مرحلة التقييم (الخليط رقم 1، 10، 20، 30، 35، 40، 050، 60، 69).

الجدول (1) المتغيرات المدروسة والحدود المُعتبرة.

البارامتر	الحد السفلي		الحد العلوي		المجال المقبول
	القيمة	رقم الخليط	القيمة	رقم الخليط	
FA-0-6 (كغ) (سطح جاف مشبع)	65.24	6	105.49	57	110 إلى 60
CA-6-12 (كغ) (سطح جاف مشبع)	27.29	2,3	52.44	19	20 إلى 60
CA-12-25 (كغ) (سطح جاف مشبع)	36.92	6	59.44	63	30 إلى 60
اسمنت (كغ)	23.15	4	35.31	57	40 إلى 20
نقاوة الاسمنت (بلين)	3890	37 إلى 1	4270	69 إلى 38	0.8 أو 0.2
HRWR (كغ)	0.14	1	0.666	23	0.7 إلى 0.1
ماء في الركامات (كغ)	0.04	67	3.5	3	4 إلى 0
ماء حر (كغ)	9.33	1	19.31	57	20 إلى 9
ملّدن ممتاز (كغ)	0.14	1	0.666	23	0.7 إلى 0.1
حالة الخلّاطة	الخليط الأول	1, 8, 15, 17, 22, 25, 30, 33, 37, 39, 41, 49, and 51	الخليط الثاني أو التالي	البقية	0.8 أو 0.2
وزن الخليط (كغ)	173.323	3	269.794	57	170 to 270

الشكل (4) قيم الهبوط لكافة الخلطات.



التساؤلات المسبقة حول البنية الهندسية لـ ANN.

أولاً، تم تنفيذ تقييم للبارامترات المختلفة، التي يمكن أن تتغير داخل الشبكة العصبونية. هذا التحليل مشروط بنوع المسألة التي واجهتنا.

- **عدد العصبونات في طبقات الدخل**: سيُرافق كل عصبون يقدم الطبولوجية للتدريب بسلسلة من الاتصالات البينية مع تابع التفعيل المرافق للوزن. أثناء الاتصال، تحدد المعلومات المتوفرة سابقاً إمكانيات التشكيلات البُعدية الفائضة للمعلومات السابقة المتوفرة. ومن جهة أخرى، يجب تجنب العدد المرتفع جداً من العصبونات لتقييد زمن الحساب.
- **عدد الطبقات**: يكون الترتيب في الطبقات مشروطاً بنفس الدوافع كعدد العصبونات. تبدو ظاهرياً أي شبكة من ثلاثة طبقات مناسبة بسبب التوافقية بين الطبقات الثلاثة وتوابع الدخل – المعالجة – الخرج.
- **تابع التفعيل والخرج**: من كافة التوابع الممكنة (خطي، عتبي، زائدي القطع، ظلي، أسي)، كان البحث مقيداً بالتوابع المستمرة والموجبة (باستثناء تابع العتبة)، كما أن المخرجات السالبة لم يُعترف بها لنفس السبب.
- **البنية الهندسية المعاودة**: وهي لم تُستخدم، بما أنه لا يوجد لديها تبرير فيزيائي خلال العملية. يعتبر تنفيذ الشبكات التي تمتلك بنية هندسية معاودة، مناسباً للمسائل التي يمكن فيها أن تؤثر نتيجة واحدة على النتيجة التالية، التي هي نموذجية في السلاسل الزمنية وليس في هذه الحالة.

التدريب باستخدام خوارزميات وراثية

تم تطوير إحداث وتدريب الشبكة العصبونية في برنامج ERNAAG (Rabunal, 1999). وهي تستخدم تقنية الخوارزمية الوراثية في تدريب أنواع مختلفة من ANN (حساب الأوزان)، كما تُستخدم أيضاً في تصميم البنية الهندسية (عدد الطبقات، عدد العصبونات لكل طبقة، وأنواع توابع التفعيل). نُفذت الاختبارات بخوارزميات تدريب معتمدة على الانتشار الخلفي من الخطأ، غير أن الاختبارات المتوفرة لم تقدم توزيعاً مستمراً داخل المجالات. ولم يتم الحصول على التقارب دائماً، وفي هذه الحالة أعطت النتائج أخطاء كبيرة.

كما تم أيضاً تصنيف البارامترات الوراثية ضمن ANN (حد قيمة الأوزان، حد الميل، نوع توابع التفعيل، والبارامترات الخاصة بالشبكات)

ما ان تُصمم السلاسل الفردية، حتى تكون المرحلة التالية هي توليد مجتمع عشوائي من السلاسل الفردية لتُطبق عليها المعاملات الوراثية. تُختار أي سلسلة فردية عشوائياً، بالإضافة إلى قيمة وزن أو ميل مُختار. تولد قيمة جديدة عشوائياً، وتُضم إلى السلسلة الفردية. يُعاد تقييم هذه السلسلة الفردية، وتُدخل إلى المجتمع اعتماداً على منسوبها الجديد للتكيف مع المسألة.

يُطبق معامل المزج في ثلاثة مراحل. تشمل المرحلة الأولى على اختيار السلاسل الفردية التي ستُمزج. وبغية تفادي أن يصبح المجتمع متجانساً جداً بنتيجة المزج المستمر للسلاسل الفردية الأفضل، يتم عشوائياً مزج سلسلة فردية من المجتمع مع سلسلة فردية أخرى من النصف الأفضل من المجتمع. هذه الاستراتيجية هي التي أنتجت النتائج الأفضل في تجارب التدريب، لأنها لا تسيء استخدام السلاسل الفردية لتكيف أفضل، وتستغل التنوع الوراثي لأي سلسلة فردية في المجتمع. بعد ذلك، تُمزج السلاسل الفردية المختارة عشوائياً. يتم توليد السلاسل الفردية الجديدة. في المرحلة الأخيرة، تُقيّم السلسلتان الفرديتان الجديدتين، ويبقى فقط السليل الأفضل في المجتمع، أما السلسلة الفردية الأخرى ذات التكيّف الأسوأ في المجتمع الابتدائي فتُزال.

تشكيل الـ ANN النهائية

نُفذت اختبارات عديدة لتحديد ANN ذات النتائج الأفضل. وقد تم تنويع وتغيير البارامترات الموضحة في الفقرة الثانوية السابقة. إن الخصائص النهائية للشبكة العصبونية المستخدمة ملخصة هنا:

- قُسمت بارامترات الدخل على أوزان الخليط، وسوّيت بين 0 و1. تغيرت المدخلات غير المستمرة (5) و(9) بين قيمتين منفصلتين 0.2 و0.8. في اختبارات متنوعة منفذة، ذُكر بأن هذه القيم أعطت نتائج أفضل من التسوية البسيطة (0/1).
- بنية من ثلاثة طبقات (17 عصبون مرتبة بالطريقة التالية: 10، 6، 1) بموجب المخطط الملحق (الشكل 5).
- تابع استيفاء ظلي زائدي القطع.
- عدد التكرارات: 6603269
- الخطأ التربيعي: 0.0146
- الخطأ الوسطي: 0.6842

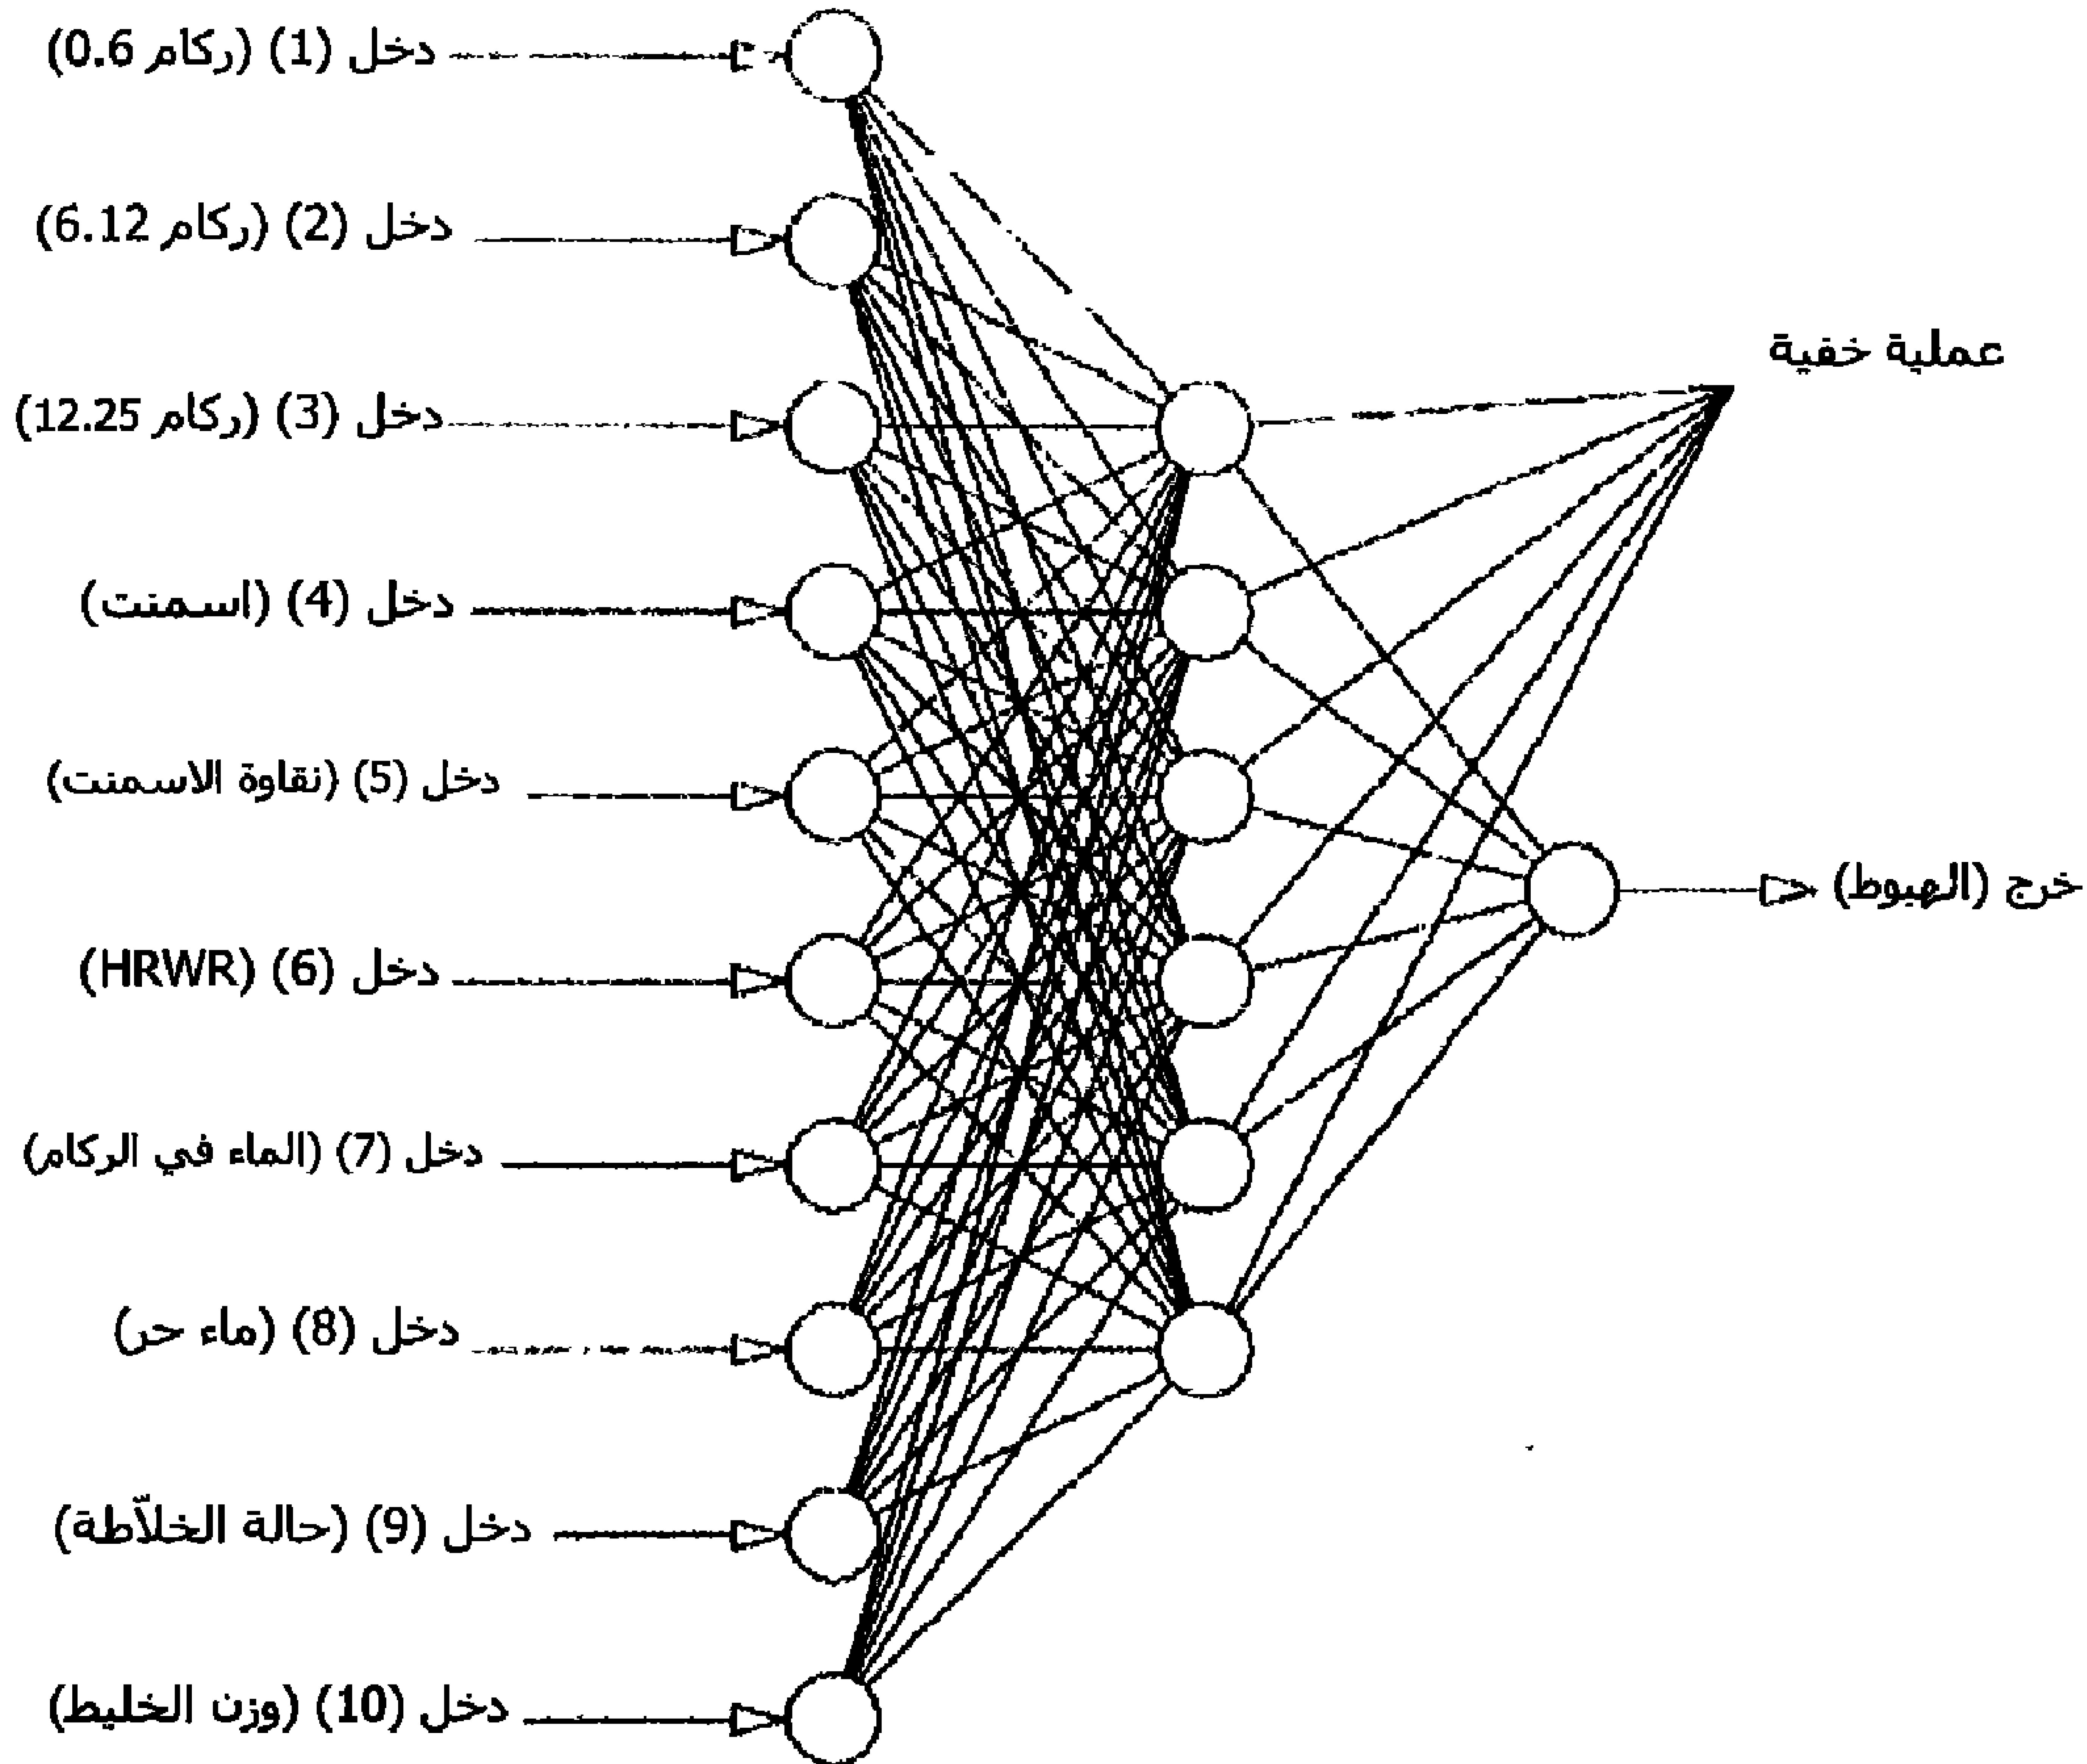
النتائج من أجل هذه الشبكة مبينة في (الجدول 2). وكما يلاحظ، فإن النتائج المعبر عنها كهبوط (سم) تُضبط بشكل معقول باستثناء في الخليط الأكثر سيولة. على الرغم من هذا، فإن تعيين التماسكية المُعطاة بالكود EHE تضبط في كافة الحالات إلى خرج ANN.

تحليل النتائج

تمتلك النتائج في الخلطات رقم 20 و40 دقة رائعة. تم تركيز الدراسة على مجموعة صغيرة من الخلطات ببارامترات ضمن فئات محدودة. من الواضح، أنه لا يمكن أن تُستنبط النتائج لأي

خليط حتى ضمن المرتبة الواحدة، طالما أن الاختبارات تأتي بامتياز من الشروط الخرسانية، التي تتضمن أنواعاً معينة من الركام، وطراز الخلاّطة ... وهلم جراً.

الشكل (5) طبولوجية الشبكة العصبونية



على الرغم من ذلك، تحدث هذه الحالة كثيراً في مصانع الجبلات، حيث أن عدد الإنتاجات غير مرتفع، وتنتج دائماً الجبلات في ظروف مماثلة جداً. تشير النتائج إلى إمكانية واضحة للتنبؤ بالتماسكية في شبكة مُدربة بخلطات قليلة. يجب ملاحظة أن التماسكية هي بارامتر حرج، بما أن بإمكانه إجبار إعادة الإنتاج عندما لا يحقق المنتج المواصفات الضرورية. وهكذا، يمكن أن تساهم الشبكة المدربة في تحليل الاهتمام بالتبعية بين بعض البارامترات والتماسكية، يتضمن الاهتمام الأكبر نسبة الماء/الاسمنت ونسبة المُلّدن الممتاز/الاسمنت.

- بغية الحصول على العلاقة بين التماسكية ونسبة الماء/الاسمنت عُدلّت البارامترات "ماء" (الدخل 8)، و"اسمنت" (الدخل 4) في خلطات حقيقية ودائماً ضمن الحدود التي من أجلها دُرِبّت ANN.

- بغية الحصول على العلاقة بين التماسكية ونسبة المُلدّن الممتاز/الاسمنت عُدلّت البارامترات "HRWR" (الدخل 6)، و"الاسمنت" (الدخل 4) في خلطات حقيقة ودائماً ضمن الحدود التي من أجلها دُرِّبت الـــ ANN.

الجدول (2) نتائج ANN (القيم المُسواة)، هبوط (سم) وتماسكية.

رقم الخليط	هبوط حقيقي			خرج ANN			الفرق
	مسوّى	5-25 سم	تماسكية EHE	مسوّى	5-25 سم	تماسكية EHE	سم
1	0,0000	0	جاف	0,1001	2,0	جاف ـ لدن	2,0
10	0,4200	10,5	سائل	0,4237	10,6	انسيابي	0,1
20	0,8000	20	سائل	0,3826	9,6	انسيابي ـ رخو	-10,4
30	0,2000	5	رخو ـ لدن	0,2641	6,6	رخو	1,6
35	0,2600	6,5	رخو	0,3656	9,1	انسيابي ـ رخو	2,6
40	0,6000	15	سائل	0,3369	8,4	انسيابي ـ رخو	-6,6
50	0,2600	6,5	رخو	0,3366	8,4	انسيابي ـ رخو	1,9
60	0,2400	6	رخو ـ لدن	0,2972	7,4	رخو	1,4
69	0,2800	7	رخو	0,3148	7,9	رخو	0,9

يظهر (الشكل 6) التحليل الأولي. يُرصد تغيير التماسكية بموجب زيادة الماء في الخليط. يوافق كل واحد من المنحنيات الثلاثة كمية المُلّدن الممتاز المُضاف. يعطي (الشكل 7) العلاقة بين التماسكية ونسبة المُلّدن الممتاز/الاسمنت من أجل خليط قياسي بنسبة ماء/اسمنت مقدارها 0.55. لقد تم توضيح بأن الإضافات تحث على إماعة الخليط، بالإضافة إلى فقدان الفعالية من الجرعات المرتفعة، التي أظهرت في النتائج المخبرية.

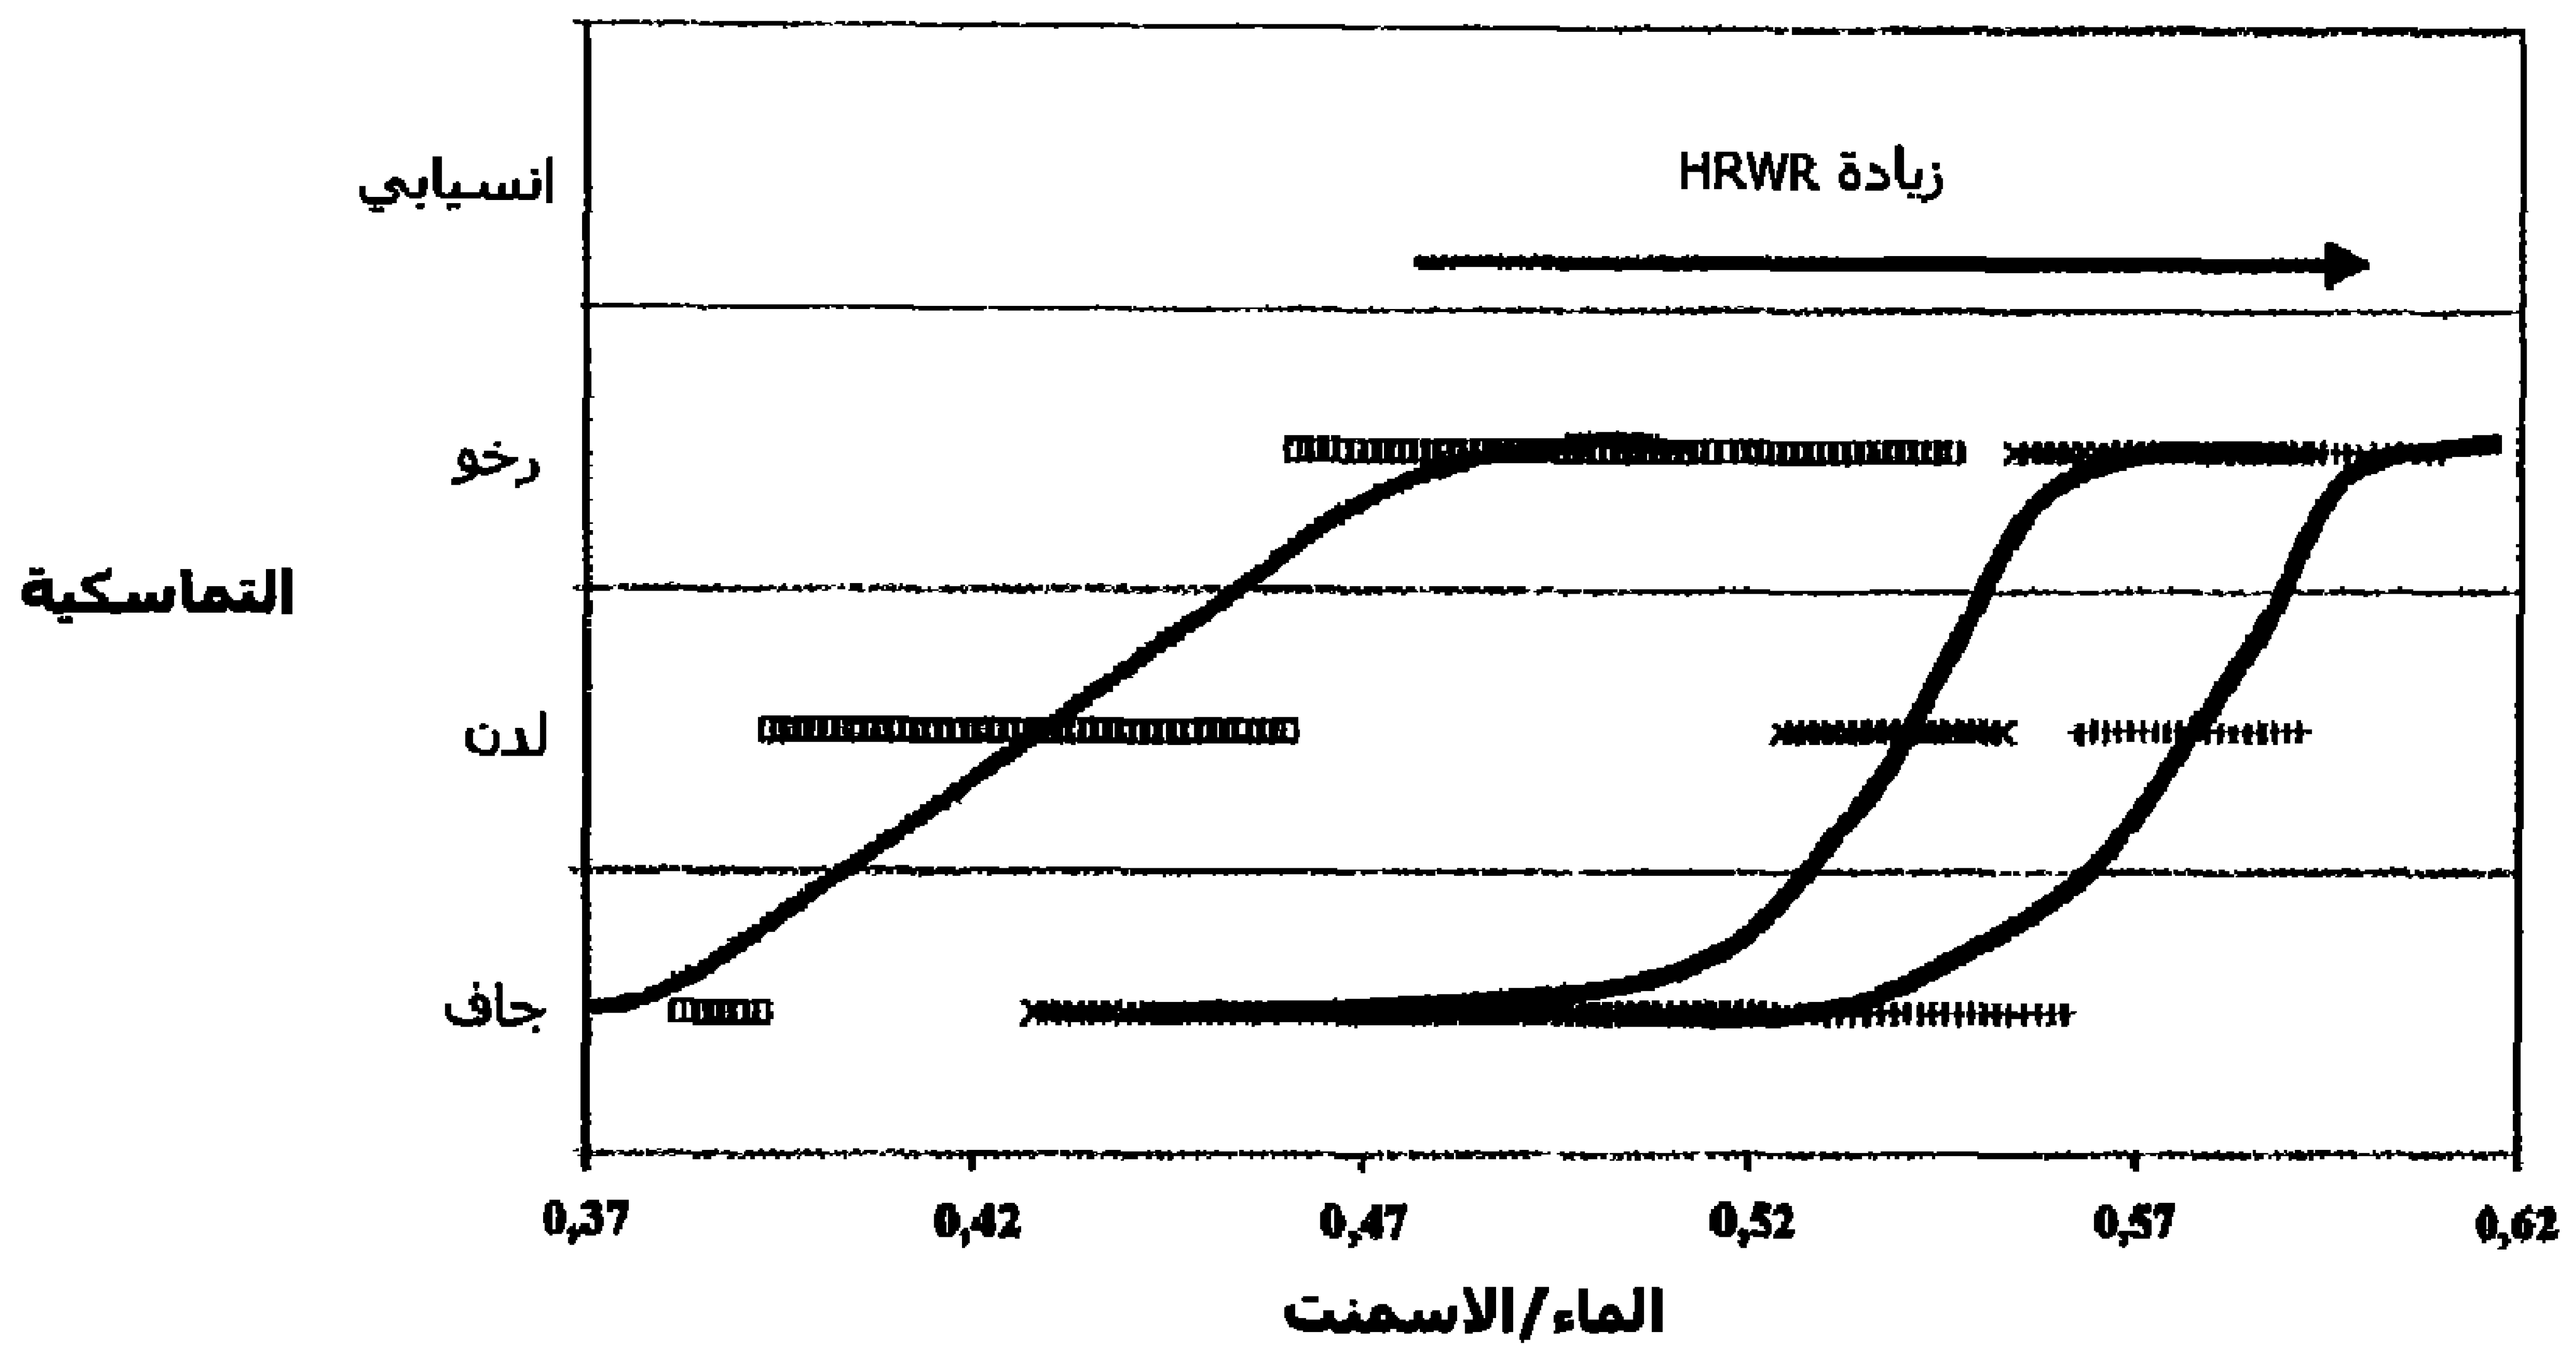
الاستنتاجات

تم وصف تطوير نماذج ANN من أجل التماسكية المُقاسة بالهبوط في حالة الخرسانة التقليدية. تؤمن النماذج ANN المبينة والمُدربة وسائل فعالة، وكمّية، وسريعة للحصول على حلول ملاءمة لقابلية التشكيل في الخلطات الخرسانية.

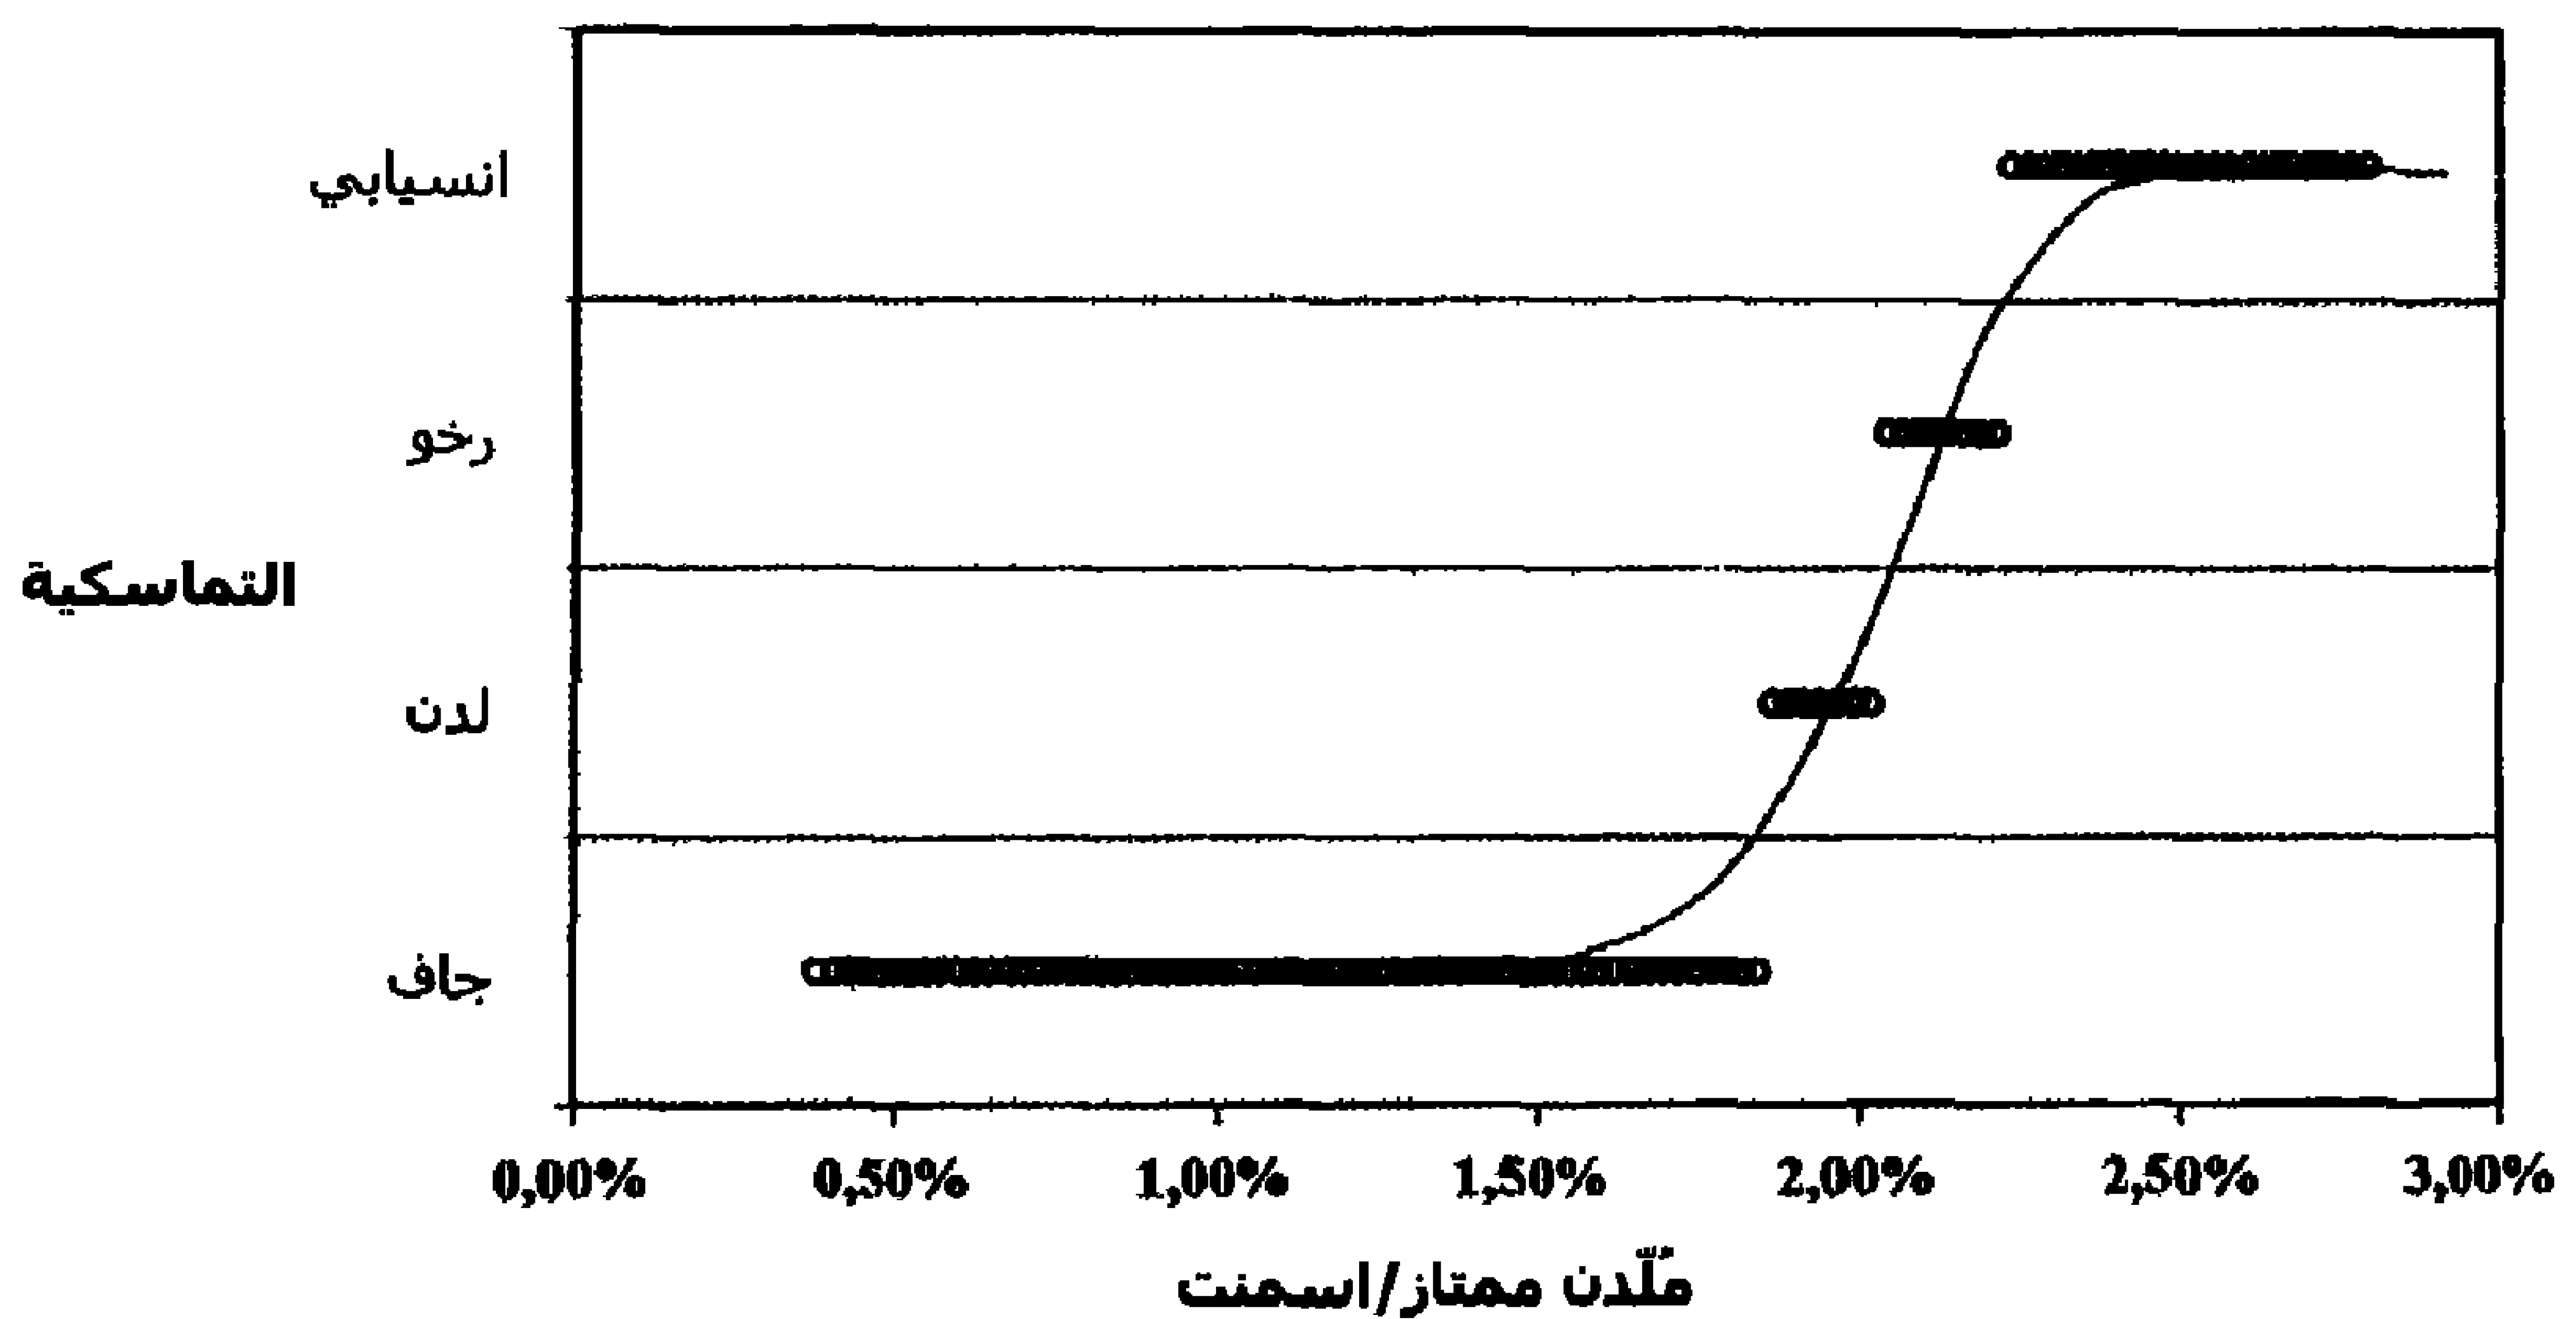
عندما لا تغطي بيانات التدريب المجال الدروس بشكل كامل، يكون استخدام الخوارزميات الوراثية أفضل من الانتشار الخلفي لعملية التدريب.

إن ANN المُولّدة تتنبأ بشكل صحيح - بطريقة عالية الجودة - بالهبوط المتوقع، عندما تُغيّر البارامترات الأساسية للخليط. ويمكن أن تكون - بالتالي - طريقة ملائمة لتصميم الخلطات ضمن الفئة المدروسة. يمكن أن تساعد الطريقة المستخدمة - بعدد أكبر من الاختبارات بفئة أكثر شمولية - في تحسين الصياغات التحليلية المستخدمة حتى الآن.

الشكل (6) *العلاقة بين التماسكية ونسبة الماء/الاسمنت: المنحنيات S مضبوطة إلى النتائج.*



الشكل (7) *العلاقة بين التماسكية ونسبة HRWR/الاسمنت: المنحني S مضبوط إلى النتائج.*



المراجع

Abrams, D.A. (1922). Proportion concrete mixtures. Proceedings of the American Concrete Institute (pp. 174-181).

EHE. (1999). Instrución de Hormigón Estructural. Publicaciones del Ministerio de Fomento. Secretaria General Técnica.

Ferraris, C.F., & de Larrard, F. (1998). Modified slump test to measure rheological parameters of fresh concrete. Cement, Concrete, and Aggregates, 20(2), 241 - 247.

González Fonteboa, B. (2002). Recycled concretes with recycled concrete aggregates: Dosages, mechanical properties and shear structural behaviour. Doctoral thesis, A Coruña, Spain.

Hu, C.,de Larrard, F.,Sedran,T.,Bonlag,C.,Bose, P., & Deflorenne, F. (1996). Validation of BTRHEOM, the new rheometer for soft-to-fluid concrete. Materials and Structures, 29(194), 620-631.

Koehler, E.P., & Fowler, D.W. (2003). Summary of concrete workability test methods. Report No. ICAR 105-1. International Center for Aggregates Research.

Rabuñal J.R. (1999). Entrenamiento de Redes de Neuronas Artificiales mediante Algoritmos Genéticos. Graduate thesis, Facultad de Informática, University of A Coruña, Spain.

Rodriguez, I. (2002). Study of concrete dosages using artificial neuronal network trained with genetical operators. A Coruña, Spain.

Tattersall, G.H. (1991). Workability and quality-control of concrete. London: E & FN Spon.

القسم 5

التحليل المالي

الفصل العاشر

طريقة الحساب الناعم لتوقع تخمين (تسعير) الصكوك

ملخص

يُشار إلى الحساب الناعم بشكل شائع كمجموعة من المنهجيات، التي تعمل بشكل مؤازر، وتؤمن إمكانيات معالجة بيانات مرنة لمعالجة الحالات الواقعية (في الزمن الحقيقي).

ويكمن هدفها في استغلال التسامح للغموض، والشك، والتعليل التقريبي لتحقيق قابلية الاستطراق والقوة. حالياً، فإن المنطق العائم (الغموض)، والشبكات العصبونية الصنعية، والخوارزميات الوراثية هي المكونات الثلاث الرئيسية للحساب الناعم. نبين في هذا الفصل تطبيق تقنيات الحساب الناعم لحل المسائل ذات الأبعاد الكثيرة. أخذنا مسألة تصنيف متعددة الصفوف للتنبؤ بتخمين الصكوك ذات 45 متغير دخل، واستُخدمت تقنيات الحساب الناعم لحلها. وتم اختيار تقنيتان هما - تقنية تخفيض البُعدية وتقنية تخفيض المتغير - وقورن أداؤهما. أُوجدت شبكات هجينة لإعطاء نتائج أفضل بالمقارنة مع طرق ANN والمنطق العائم العادية. كما قمنا أيضاً بمقارنة كافة النتائج بتقنيات تراجع عادية.

مقدمة

يُشار إلى الحساب الناعم بشكل شائع كمجموعة من المنهجيات التي تعمل بشكل مؤازر، وتؤمن إمكانيات معالجة بيانات مرنة لمعالجة الحالات الواقعية. ويكمن هدفه في استغلال الغموض، والشك، والتعليل التقريبي لتحقيق قابلية الاستطراق والقوة. يمثل المنطق العائم (Wang, 1997) والشبكات العصبونية الصنعية (Mehrotra, 1997;) (Hassoun, 1995)، والخوارزميات الوراثية (Deb, 2001) حالياً المكونات الرئيسية الثلاثة للحساب الناعم. تلائم ANN بناء بنى هندسية للتعلم التكيفي. وتُستخدم GA للبحث والأمْثلة. أما طرق المنطق العائم فتؤمن التعامل مع عدم الدقة والشك. تعتمد القيمة التحليلية لكل نوع من هذه الأدوات الثلاث على التطبيق.

تتعلم الشبكات العصبونية من التجربة، وتُستخدم بشكل خاص في تمييز الأنماط والأشكال (Mehrotra, 1997, Hassoun, 1995). وهذا ما يميز الشبكات العصبونية عن برامج الحساب التقليدية، التي تنفذ التعليمات ببساطة في ترتيب متسلسل ثابت. أما أنظمة الاستنتاج والاستدلال العائمة (Wang, 1997)، فهي مفيدة للحالات حيث تحتاج لأن تكون خبرة الإنسان (التي لا يمكن أن تترجم إلى مجموعة من المعادلات) مدمجة في عملية اتخاذ قرار مؤتمتة (على سبيل المثال، التحكم بمحطة قدرة). البرمجة التطورية، والاستراتيجيات التطورية، والخوارزميات الوراثية (Wang, 1997) مفيدة لمسائل الأمْثلة حيث يكمن اختلافها الخاص في كيفية تفاديها للنهايات المحلية (أي جعل الخطأ أصغرياً لتقدير البارامتر).

نعين مسائلاً عالية البُعدية كتلك المسائل التي تمتلك عدداً كبيراً نسبياً من متغيرات الدخل.
الافتراض 1: مسألة ذات n متغير دخل يقال أنها مسألة ذات n بُعد.

استخدمنا في هذا الفصل تقنيات الحساب الناعم لمعالجة مسائل عالية البُعدية. وأخذنا كمثال مسألة تنبؤ تخمين الصكوك (Sengal, Ramasubramanian, & Rajesh 2001، Chaveesuk, Srivaree-ratana & Smith 1999). إن التنبؤ بتخمين الصكوك هي مسألة تصنيف متعددة الصفوف، ما يجعلها مسألة عسيرة جداً للحل.

وفقاً لوكالة Standard & Poor (S&P)، "فإن تخمين الصكوك أو الائتمان هو رأي الاعتماد العام لمتعهد، فيما يتعلق بأمن دين معين أو التزامات مالية أخرى معتمدة على عوامل مخاطرة ذات صلة".

عندما يُسلّف المستثمرون المال للشركات أو الحكومات، فإنها تكون غالباً على هيئة صكوك كقرض ممكن الاتجار به صادر عن شركة الاقتراض. يجب على مشتري الصكوك أن يقوموا بتقييم مماثل على اعتماد الشركة المُصدرة وفقاً لبياناها المالي (الميزانية وحساب الدخل)، من خلال توقعات التنمية الاقتصادية المستقبلية. غالبية مشتري الصكوك لا يملكون مصادر لتنفيذ هذا النوع من البحث الصعب والمستهلك للوقت. لحسن الحظ، يوجد ما يسمى بوكالات التخمين المتخصصة في تقييم الاعتماد لأي شركة. الائتمان الناتج أو تخمين الصكوك هو قياس لمخاطرة الشركة، التي لا تكون قادرة على تسديد دفعة فائدة أو فك رهن سندها المُسلّم. علاوة على ذلك، فإن مقدار دفع الفائدة على الصك يعتمد على الاحتمال المتوقع للتخلف أو التقصير. يدل التخمين الأعلى على بينة أقل مخاطرةً لاستثمار مالك وفائدة أقل مُستلمة على الصك. بينما يشير التخمين الأقل إلى شركة أكثر مخاطرة، ويجب على الشركة أن تدفع دفعة أكبر لنفس مقدار المال الذي نريد اقتراضه. لسوء الحظ، لم تُخمن كل الشركات حتى الآن. كما أن وكالات التخمين تكون غالباً بطيئة في تعديل تخميناتها للمعلومات الهامة الجديدة لشركة ما أو

محيطها. وفي بعض الأحيان، تقوم وكالات تخمين مختلفة بتعيين تخمينات مختلفة لنفس الشركة. في كافة هذه الحالات، نريد أن نكون قادرين على تشكيل تخميننا الخاص لاعتماد الشركة باستخدام نفس معايير وكالات التخمين. وهذا الأمر صعب، لأن عملية التخمين غير متوفرة لعامة الناس خارج الوكالات. تحمي وكالات التخمين بشكل مباشر عملية تخمينها، فهم يصرحون فقط بأن العوامل المالية والنوعية تؤخذ بالحسبان عند تعيين التخمينات للشركات.

نريد أن نحاول فتح هذا الصندوق الأسود بتوصيف العلاقة بين البيان المالي لشركة ما وتخمين الرصيد المعين. وقد يمكننا هذا من القول، أن تخمين شركة ما متأثر بالتحليل النوعي المُنفذ من قبل وكالة التخمين. ويمكن بالطبع أن تُستخدم المعرفة الناتجة لتصنيف الشركات، التي لم تُخمن بعد، أو التي تغيرت جوهرياً مؤخراً.

قد يعطي تخمين الائتمان إلى المدن والبلدات والبلدان ... الخ بمعزل عن صكوك الدين. وهنا نأخذ بالاعتبار صكوك الدين فقط. نموذجياً، يوجد في السوق عدد من الصكوك، التي لا تكون مُخمنة (مُسعّرة). وقد يرغب مستثمر ما، الذي يريد أن يستثمر في هذه الصكوك، بأن يكون لديه بعض الفكرة حول تخمين الصك. يتعامل هذا المشروع مع تعيين صف تخمين لصك غير مُخمن.

فحص المادة المطبوعة حول هذا الموضوع

تقدر أي وكالة تخمين العوامل ذات الصلة المتعلقة باعتماد المُصّدر. وهي تتضمن العوامل الكمية مثل ربحية الشركة، ومقدار الدين القائم، وكذلك العوامل النوعية مثل مهارة الإدارة، والتوقعات الاقتصادية للشركة. ثم يُوجز كامل التحليل في تخمين حرفي مطبوع. قامت كل من وكالة Standard & Poor (P&S) ووكالة Moody بتخمين الصكوك لمدة قرن تقريباً، وهما وكالتا التخمين الرئيستان حتى الآن. وهناك مؤسسات تخمين محترمة أخرى هي Fitch و(Duff & Phelps (DCR. وفي الهند تقوم الوكالتان CRISIL وICRA بنفس الأمر.

تستخدم وكالات التخمين المختلفة طرقاً مختلفة لتخمين الصكوك، وتختلف أيضاً تخمينات الصكوك من وكالة إلى أخرى. بشكل عام، تتبع التخمينات المستخدمة نفس المعايير، ولكن قد توجد بعض الاختلافات التي تؤدي إلى التخمينات المتفاوتة بين وكالات التخمين. التخمينات المختلفة التي تعطيها بعض وكالات التخمين للصكوك مبينة في (الجدول 1).

الجدول (1) مقاييس التخمين.

Moody's	S&P	Fitch	DCR	تعاريف
Aaa	AAA	AAA	AAA	رئيسي. الأمان الأقصى
Aa1	AA+	AA+	AA+	الدرجة العالية. النوعية العالية
Aa2	AA	AA	AA	
Aa3	AA-	AA-	AA-	
A1	A+	A+	A+	مرحلة متوسطة عليا
A2	A	A	A	
A3	A-	A-	A-	
Baa1	BBB+	BBB+	BBB+	مرحلة متوسطة سفلى
Baa2	BBB	BBB	BBB	
Baa3	BBB-	BBB-	BBB-	
Ba1	BB+	BB+	BB+	مرحلة غير استثمارية
Ba2	BB	BB	BB	تضاربي
Ba3	BB-	BB-	BB-	
B1	B+	B+	B+	تضاربي بشكل كبير
B2	B	B	B	
B3	B-	B-	B-	
Caa	CCC+	CCC	CCC	مخاطرة كبيرة
	CCC			في مكانه سيئة
	CCC-			
Ca				تضاربي للغاية
C				قد يكون في التخلف (تقصير)
		DDD		تخلف
		DD	DD	
	D	D		
			DP	

الطرق الإحصائية لتخمين الصكوك

إن عملية تخمين الصكوك، كما هي منفذة من قبل لجنة خبيرة لوكالة مالية معينة، تكون غالباً مخبأة لأنها من القضايا السرية. وفقاً لذلك، فقد حاول العديد من الباحثين صياغة طرق بديلة لتوقع تخمينات الصكوك – كالطرق الكلاسيكية وطرق معالجة المعرفة الإنسانية – مع التركيز على الطرق الإحصائية. ركزت الدراسات السابقة على تحليل تراجع خطي، وتحليل مميز خطي (Everitt & Dunn, 2001; Maddala, 1997). انتقد العديد من الباحثين (Refenes, 1994)

استخدام تقنيات التحليل الإحصائي التقليدية - وكنماذج التراجع المتعددة - بما أنها حققت نجاحاً محدوداً في توقع تخمينات الصكوك، لأن التطبيق لا يلتزم بأشكال وظيفية عامة. على أية حال، تُطبق حالياً الشبكات العصبونية، والأنظمة العائمة، والأنظمة الخبيرة الأخرى لحل مثل هذه المسائل الخاصة بالتصنيف متعدد الصفوف (Chaveesuk, Srivaree-ratana & Simth, 1999). إحدى طرق معالجة المعرفة الإنسانية هي استخدام نظام خبير يعتمد على تقنيات هندسة المعرفة. فهو ينفذ مهمة التصنيف باستخدام مجموعة قواعد مُصاغة من قبل خبراء. تُشتق القواعد وفقاً لآراء الخبراء في تأثيرات كل متغير مالي ذي صلة. مع ذلك، فمن الصعب جداً تطوير نظام خبير معتمد على القواعد من أجل تخمين الصكوك، بسبب قلة الخبراء المتوفرين وسرّية غالبية المعرفة حول معالجة التخمين.

صياغة المسألة

إن توقع تخمين الصكوك هو نوع متعدد التصنيف من المسائل، بما أنه يتعامل مع مجموعة من متغيرات دخل تُطابق مع مجموعة من الصفوف (الاصناف) المنفصلة والمتعارضة. تُشكل هنا إصدارات الصكوك المختلفة مجموعة حالات بيانات الدخل، وتشكل تخمينات الصكوك المتنوعة مجموعة الصفوف المحتملة، التي يمكن أن تنتمي إليها صكوك الدخل. يجب أن تُعيّن الصكوك إلى صف ما وصف واحد فقط.

تم أخذ 15 نوعاً من تخمينات الصكوك (كما هو مذكور في الملحق) و46 متغير من أجل تنبؤ تخمين الصكوك. كما في الاقتراح 1، فإنها مسألة ذات 46 بُعداً. يكمن السبب في اختيار العديد من المتغيرات، في أن تدمج معلومات كثيرة قدر الإمكان عن الشركات.

يجب أن يكون النظام قادراً على تعلم التبعيات في البيانات. طالما أن مسألة كهذه صعبة جداً، فقد تم تجريب نوعين من التقنيات. هما تقنية التخفيض البُعدي (باستخدام PCA)، وتقنية تخفيض المتغير، وتمت مقارنة نتائجها باستخدام ثلاثة أنواع مختلفة من تقنيات التعلم غير المُراقب هي:

1. شبكة Kohonen أو الخريطة ذاتية التنظيم: وهي طريقة معتمدة على الشبكة العصبونية (Hassoun, 1995)
2. الوسيلة الغامضة (FCM)، وهي طريقة العنقدة المعتمدة على المنطق العائم (Bezdek, 1981، Bezdek & Pal, 1992).
3. شبكة Kohonen الغامضة، وهي نظام عصبوني غامض (Taso, Bezdek, & Pal, 1994).

شبكات Kohonen

تم تطوير شبكة Kohonen (Kohonen, 1989) أو "الخريطة ذاتية التنظيم" (SOM) من قبل العالم Teuvo Kohonen. إن الفكرة الأساسية وراء هذه الشبكة هي تركيب بنية وحدات المعالجة المتصلة بينياً (العصبونات)، التي تتنافس من أجل الإشارة. تعرف SOM نقلاً ما من فضاء بيانات الدخل الممتد بـــ $X_1...X_n$ إلى مصفوفة احادية أو ثنائية البعد من العقد. يُنفذ النقل بطريقة ما بحيث يتم المحافظة على الطبولوجية في فضاء الدخل ذو n بُعد عند نقلها إلى SOM. بالإضافة لذلك، فإن الكثافة المحلية للبيانات تُعكس أيضاً بالخريطة، ومناطق فضاء بيانات الدخل، التي تُمثل بواسطة بيانات أكثر تُنقل إلى منطقة أكبر من SOM. كل عقدة من الخريطة مُعرفة بواسطة الشعاع W_{ij}، الذي تُضبط عناصره خلال التدريب.

إن خوارزمية التدريب الأساسية بسيطة جداً وهي:

1. بدء أوزان الخلية العصبونية بقيم عشوائية.
2. اختيار غرض ما من مجموعة التدريب.
3. إيجاد العقدة – الوحدة الفائزة m_c، التي تكون قريبة من البيانات المختارة (أي أن المسافة بين Wij ومجموعة التدريب أصغرية).

$$// X - m_C // = \min_i // X - m_i //$$

4. ضبط أشعة الأوزان للعقدة الأقرب وللعقد المحيطة بها بطريقة ما، بحيث تتحرك mi باتجاه مجموعة التدريب:

$$m_i(t + 1) = m_i(t) + h_{ci} . [x(t) - m_i(t)]$$

حيث أن:

$$h_{ci} = h_0 \exp\left[-\frac{// r_i - r_C //^2}{\sigma^2}\right]$$

5. $h_0 = h_0(t)$ و$\sigma = \sigma(t)$ كتوابع الموت الملائمة للوقت، وتشير r_c وr_i إلى إحداثيات البنية الهندسية للعصبون الفائز وللعصبون i على الترتيب.
6. تكرار البدء بالخطوة 1 من أجل عدد ثابت من التكرارات.

إن كمية الضبط في الخطوة 3 – وكذلك مجال الجوار، ينخفض خلال التدريب. وهذا يضمن بأن يوجد ضبط خشن في الطور الأول من التدريب، بينما يحدث الضبط الناعم أثناء نهاية التدريب.

تعكس خريطة Kohonen البنية الداخلية لبيانات الدخل. مع ذلك، لا يستطيع أحد القول أي العصبونات تُنشط بأي أشعة دخل. بالإضافة لذلك، فإن العصبونات الموافقة لبعض أشعة الدخل بعد تدريب معين، ستوافق مجموعة أخرى من الأشعة بعد تشغيل تدريب آخر. لذا، يجب أن تُعاير SOM. ويمكن تنفيذ هذا بتقديم أمثلة معروفة جيداً للشبكة، وبتسجيل ما هو العصبون الذي نُشط بشعاع مثال معطى. بما أن خرائط Kohonen تميل إلى تشكيل نوع معين من السطح المرن على مجال أشعة الدخل لبيانات التدريب، فإن العصبونات التي لم تُنشط خلال عملية المعايرة، قد تُفسر بالاستيفاء.

FCM

إن خوارزمية وسيلة -C العائمة (FCM) معطية سويةً مع ميزاتها وعيوبها. تعتمد هذه الخوارزمية التكرارية على طريقة تساوي البيانات الكلاسيكية للعالمين Ball وHall(1967). يجب أن يكون عدد العناقيد C، معطياً مسبقاً، حيث يكون C مساوياً أو أكبر من اثنان، ومساوياً أو أقل من عدد الأغراض K. بالإضافة لذلك، يجب أن يُعطى أيضاً ما يسمى بالأس m ‏(1.0 < m).

يحدد الأس m درجة عائمية عملية العنقدة الناتجة. عندما تكون m ← 1، فإن عائمية نتيجة العنقدة تميل إلى النتائج المشتقة بطريقة تساوي البيانات الكلاسيكية. وعندما m ← ∞، فإن قيم العضوية لكافة الأغراض لكل عنقود تميل إلى مقلوب عدد الصفوف 1/C. يبين القسم التالي شرحاً مفصلاً أكثر لعملية العنقدة.

العنقدة (التدريب)

إن خوارزمية العنقدة (أو التدريب) لخوارزمية وسيلة -C العائمة تقرأ كالآتي:

1. البدء بقيمة العضوية Mik لـ Xk لـ K غرض لكافة العناقيد i من أجل i = 1, ..., c و k = 1 ... K (على سبيل المثال عشوائياً) بحيث:

$$\sum_{i=1}^{C} M_{ik} = 1 \forall K = 1,\ldots,K \; and \; M_{ik} \in [0,1] \forall K = 1,\ldots,K, \forall i = 1,\ldots,C$$

2. حساب مراكز العناقيد باستخدام قيم العضوية تلك:

$$V_i = \frac{\sum_{K=1}^{K} (M_{iK})^m X_K}{\sum_{K=1}^{K} (M_{iK})^m} \forall_i = 1,\ldots,C$$

3. حساب قيم العضوية الجديدة M_{iK}^{New} باستخدام مراكز العناقيد تلك:

$$M_{iK}^{New} = \left[\sum_{i}^{C} = 1 \left(\frac{//V - X_i //_A}{//V_K - X_j //_A} \right)^{\frac{2}{m-1}} \right]^{-1} \quad \begin{array}{l} \forall i = 1,...,C \\ \forall K = 1,...,K \end{array}$$

4. f//MNew - M// > ∈، ليكن M = MNew واذهب إلى الخطوة 2.

لحساب مسافات الأشعة في الخطوة 3 يلزم اختيار قياس ملائم للمسافة. تنتهي العملية عندما تهبط المسافة بين مصفوفتي عضوية متعاقبتين إلى أقل من عتبة تقارب مشترطة.

العنونة

لكي يكون من الممكن تطبيق مراكز العناقيد الموجودة كمصنفات، يجب إعطائها أسماءً معقولة. تدعى عملية تعيين أسماء الصفوف لمراكز العناقيد بالعنونة. أي طريقة عنونة من أجل خوارزمية وسيلة -C العائمة هي التفتيش عن مراكز العناقيد وقيم عضويتها الخاصة للميزات المختلفة، وتعيين عنوان ما يدويا.

تكمن الفكرة الرئيسية لهذا الاجراء في تقديم عينة من الأغراض إلى مُصنّف وسيلة -C العائمة الذي تكون أعضاء صفة معلومة (على شكل قيم 1/0)، كما تم أيضاً حسابه بالخوارزمية. بواسطة معلومات عضوية العناقيد المعطية لكل جسم فردي وقيم العضوية لكل مركز عنقود، يمكن أن تُرافق مراكز العناقيد بصفوفها الخاصة. يُنفذ ربط أسماء الصفوف إلى مراكز العناقيد بمصفوفة حساب. بفرض لدينا c عناقيد ومجموعة من الأمثلة X_K ينتمي كل واحد إلى صف عنقود {1, ..., C} = (K)، تكون مصفوفة الحساب ذات قياس C × C وجميع عناصرها ذات قيم ابتدائية صفرية.

يمكن بعد ذلك أن تعنون مراكز العناقيد آلياً بالخوارزمية التالية:

1. حساب تابع العضوية MiK للغرض XK من الصف (K) لكافة مراكز العناقيد Vi

$$M_{iK} = \left[\sum_{j}^{C} = 1 \left(\frac{//V - X_i //_A}{//V_K - X_j //_A} \right)^{\frac{2}{m-1}} \right]^{-1} \quad \forall i = 1,...,C$$

2. ليكن Pclass(K), i = Pclass(K), i + MiK, ∀i = 1, ..., C

3. اذهب إلى الخطوة 1 حتى تُعالج كافة الأمثلة Xx بالخطوة 1 و2.

4. تحديد $L_i = \max_{K=1,\dots,C} \{P_{k,i}\}$ من أجل i = 1, ..., C
5. تعيين العنوان Li لمركز العنقود Vi.

يفشل الأجراء، إذا تم تعيين عنوان ما إلى صفين أو أكثر، الذي يعني بأن مركز العنقود لم يوجد لكافة عناوين الصفوف. في حالات نادرة، يمكن أن يحدث بأن لا تكون القيمة الأعظمية لمصفوفة الحساب في الخطوة 4 مثبتة بلا شك. تُقطع الخوارزمية في كلا الحالتين بتقرير خطأ.

شبكة عنقدة Kohonen العائمة (FKCN)

شبكة عنقدة Kohonen العائمة (FKCN) (Tsaoet et al. 1994) هي نموذج عصبوني عائم، تكون المجموعات العائمة والشبكات العصبونية الصنعية فيه موجودة جنباً إلى جنب في نموذج كامل واحد بدلاً من أن تكون نماذج مستقلة. وبشكل محدد، فإن خريطة Kohonen ذاتية التنظيم (Kohonen, 1989) مُدمجة بخوارزمية وسيلة -C العائمة (Bezdek, 1981).

خوارزمية التدريب

عند تدريب شبكة Kohonen العائمة، يُحدد معدل تعلم شبكة Kohonen جوهرياً بشكل ديناميكي بواسطة خطوة -C العائمة. لايحدث تكيّف لجيران العصبون، وهي مختلفة جوهرياً عن خوارزمية تدريب شبكة Kohonen في أن أي خطوة تعلم تأخذ دائماً بالحسبان كافة أمثلة التدريب معاً. كما تُدرب شبكة Kohonen العائمة أيضاً باستخدام استراتيجية تراكمية، بينما تستخدم شبكة Kohonen تعلماً أحادي الخطوة.

يتم التحكم بعملية التدريب بواسطة بارامترين: الأس m_0، وخطوة الأس Δm. يوافق الأس m_0 أس خوارزمية وسيلة -C العائمة (انظر فقرة خوارزمية وسيلة -C العائمة). وتتحكم خطوة الأس Δm بمعدل نقصان ضبط أوزان العصبونات. لاستمرار النظير بتدريب وسيلة -C العائمة، تُعطى عتبة تقارب $\varepsilon > 0$.

إن خوارزمية تدريب شبكة Kohonen العائمة هي كالتالي:

1. يتم بدء العناصر Wij لشعاع الوزن Wi باستخدام أرقام عشوائية.
2. حساب العضوية uiK(t) للعصبونات الفردية لكل شعاع دخل Xx:

$$u_{iK}(t) = \sum_{j=1}^{C} \left(\frac{// X_K - W_i(t) //}{// X_K - W_j(t) //} \right)^{\frac{-2}{m(t)-1}} \qquad \forall i = 1,\dots,C \quad \forall K = 1,\dots,K$$

حساب معدل التعلم αiK(t) باستخدام القيم العضوية:

$\alpha_{iK}(t) = (u_{iK}(t))^{m(t)}$

3. ضبط أشعة الأوزان Wi بحيث:

$\forall i = 1, ..., C$

4. ليكن $m(t + 1) = m(t) - \Delta m$. إذا كان $m(t + 1) > 1.0$ و$//W(t + 1) - W(t)// > E$ اذهب إلى الخطوة 2.

حيث أن K – هو عدد أمثلة التدريب، وC – عدد العصبونات في الشبكة. تحتفظ طريقة التدريب هذه بخصائص ذاتية التنظيم لخريطة ميزات Kohonen. ولكن بدلاً من استخدام جوار واضح لضبط الأوزان، يُحسب معدل التعلم الفردي لكل عصبون باستخدام الأس الحالي. بهذا الأسلوب، يركز التدريب على العصبون الفائز. ينتج الهبوط في معدل الأس بطرح خطوة الأس بعد كل تدريب في $m(t) \leftarrow L$، بمعنى أن معدل التعلم مُركز أكثر على العصبون الفائز، في الحالة الحدية $m(t) = 1$، سيكون العصبون الفائز فقط متكيفاً.

على أية حال، بما أن جيران العصبونات على الخريطة لم تؤخذ بالاعتبار بشكل واضح، عند استخدام هذا الاجراء فإن الخصائص المرئية لشبكة Kohonen تُفقد. وبما أنه يُنجز ضبط أوزان العصبون فيما يتعلق بكافة أشعة السمات، فإن العملية مستقلة عن ترتيب تقديم أمثلة التدريب (بعكس شبكات Kohonen).

بهذا الأسلوب، وبدمج خوارزمية وسيلة -C العائمة إلى الشبكة، يتم تفادي نقاط ضعف شبكة Kohonen المذكورة. علاوة على ذلك، يظهر أيضاً بأن خصائص التقارب للشبكة تُحسّن، ويلزم دورات تدريب أقل بكثير لإتمام المهمة (Bezdek & Pal, 1992). وهذا بحد ذاته هو أفضلية على شبكة Kohonen بتوفير وقت كثير في مرحلة بناء النموذج في الحالة، التي تكون فيها خطة الأس مختارة، ويكون عدد العصبونات على خريطة Kohonen هو نفس عدد الصفوف. عندئذ، تكون الخوارزمية مكافئة لخوارزمية وسيلة -C العائمة. وإذا وجدت عصبونات أكثر من الصفوف المتوقعة، فإنها تمتلك أفضلية على خوارزمية وسيلة -C العائمة في أنه يمكن أن يمثل من عصبون واحد صف ما. وبالتالي، يمكن أن تُبنى حدود صفوف أكثر تعقيداً. تنتج حدود الصفوف الكروية الهجينة للعصبونات الفردية حد صف محصّل. في هذه الحالة، لا يتحدث أحد بعد ذلك عن مراكز الصفوف، بل على العكس يتحدث عن تمثيلات الصفوف.

منهجية الحل

اختيار الدخل

أُختيرت المدخلات من مجال واسع من المتغيرات التي تتضمن نسب ربحية الشركة، نسب المبيعات، العمر، ... الخ. تصف هذه المصفوفات حجم المنظمة، الربحية، النفوذ، السيولة، والالتزامات. يكمن السبب الجوهري وراء اختيار متغيرات عديدة كهذه في أن تتضمن معلومات كثيرة حول الشركة قدر الإمكان، بحيث يتعلم النظام التبعيات في البيانات. على أية حال، فقد أُكتشف بأن العوامل النوعية مثل أداء الإدارة، وثقة المستثمر، والعوامل غير المالية مثل مخاطرة السوق ومخاطرة الإدارة... وهلم جراً. جميعها مؤثرة جداً في تخمين الصكوك/الشركة. على أية حال، طالما أن البياناتِ غير المالية ليست متوفرة، وطالما أن العوامل النوعية تصبح أكثر شخصيةً، فإننا نستخدم فقط البيانات المالية. يتألف الدخل من 45 نسبة مالية (Manuj, 1993). بمعزل عن النسب الحالية، أُستخدمت أيضاً بيانات أخرى معلومة كعمر الشركة. قائمة بارامترات الدخل المُعتبرة مبينة في (الجدول 2).

المعالجة المسبقة

لم تكن متغيرات الدخل المختارة بنفس المقياس (الحجم). وبالتالي، كان مطلوباً إجراء تسوية. ولهذا السبب، تمت تسوية كل متغير دخل إلى شكل طبيعي قياسي.

تخفيض البُعدية

يمكن أن يُستخدم تحليل المكونات الرئيسية (Everitt & Dunn, 2001؛ Maddala, 1997) من أجل تخفيض البعدية. وهو يصف تغيير مجموعة البيانات متعددة المتغيرات على هيئة مجموعة من المتغيرات غير المرتبطة، التي تمثل توليفات خطية من التغيرات الأصلية.

مصفوفات الأداء

من أجل مسألة تصنيف متعددة الصفوف مثل توقع تخمين الصكوك، يمكن أن تُطبق طرق متعددة لقياس الدقة والأداء. وقد اخترنا حساب عدد التسجيلات (أو البيانات التي صُنّفت بشكل صحيح)، وعدد العينات المُصنّفة خطأً في الاتجاه الآخر (Sehgal et at., 2001). إن تخميناً أعلى للصك مُصنّف خطأً ليكون أخفض أقل أهمية من تخمينٍ أخفض للصك مُصنّف كتخمين أعلى.

الجدول (2) متغيرات الدخل

الربح قبل إيراد السهم الحالي (nnrt)/ المبيعات	معدل المدينون/معدل الممتلكات الحالية
الربح قبل الضربة (nnrt)/المبيعات	معدل رأس المال العامل/كامل المبيعات
الربح قبل إيراد السهم المالي (nnrt)/معدل رأس المال المستخدم	معدل رأس المال العامل/المبيعات
الربح قبل إيراد السهم المالي (nnrt)/الفائدة	الاقتراضات/قيمة الربح الصافي
الربح قبل الضربة (nnrt)/كامل الممتلكات	كامل الاقتراضات/قيمة الربح الصافي
مبيعات/كامل الممتلكات	كامل الاقتراضات/كامل الممتلكات
مبيعات/الممتلكات الحالية	(ربح التشغيل ـ فائدة)/كامل الممتلكات
المبيعات/رأس المال المستخدم	كامل الدخل/قيمة الربح الصافي
قيمة الربح الصافي كامل المسؤوليات القانونية	ربح التشغيل/كامل الممتلكات
حجوزات/كامل الممتلكات	ربح التشغيل/رأس المال المستخدم
معدل أيام الدائنين	ربح التشغيل/المبيعات
معدل أيام المدينين	الأرباح النقدية/المبيعات
معدل أيام الدائنين/معدل أيام المدينين	الأرباح النقدية/كامل الاقتراضات
معدل الجرد/معدل الممتلكات الحالية	الأرباح النقدية/رأس المال المستخدم
معدل الجرد/المبيعات	معدل نقد مصرف/معدل الممتلكات الحالية
معدل الجرد/معدل رأس المال العامل	معدل نقد مصرف/ الممتلكات سريعة
معدل الجرد/معدل كامل الممتلكات	الممتلكات الحالية/المبيعات
معدل الجرد/معدل التكلفة اليومية للإنتاج	الممتلكات الحالية/كامل الممتلكات
كامل الممتلكات	الممتلكات الحالية/المسؤوليات القانونية الحالية
المبيعات	الممتلكات السريعة/كامل الممتلكات
العمر	الممتلكات السريعة/المسؤوليات القانونية الحالية
(إعلان + توزيع + تسويق)/المبيعات	(أرباح نقدية/الجزء المالي من المسؤوليات القانونية طويلة المدى + الفائدة)
كامل نفقة المادة الخام + الطاقة + الضرائب غير المباشرة + الأجور + نفقات تشغيل أخرى)/ المبيعات	

ملاحظة: (nnrt) تعني أنه تم إزالة الفائدة الضريبة بعد الدخل والإنفاق الاستثنائي من الحسابات.

الوضعية التجريبية

مصادر البيانات

البيانات المأخوذة من أجل توقع التخمين هي بيانات CRISIL 1999 (Rating Scan, 1999)، حيث أن CRISIL هي وكالة تخمين صكوك مشهورة في الهند. نموذجياً، تتضمن المستندات المتعلقة بوكالات التخمين الآتي:

- مستندات دين طويلة الأمد (على سبيل المثال، صكوك، مستندات).
- مستندات دين متوسطة الأمد (على سبيل المثال، ودائع لأجل محدد).
- مستندات دين قصيرة الأمد (على سبيل المثال، الأوزان التجارية).
- الالتزامات المُنظمة.
- الأسهم الممتازة.

لقد أُستخدمت تخمينات ائتمان مستندات دين طويلة الأمد لشركات صناعية من أجل التجارب. وقد جُمعت البيانات حول الشركات من قاعدة بيانات المهارة العالية المحافظ عليها من قبل مركز مراقبة الاقتصاد الهندي (CMIE).

مجموعات البيانات المستخدمة

- **مجموعات بيانات التدريب**: تتألف مجموعة بيانات التدريب من 170 تسجيلاً (كافة الصفوف متضمنة).
- **مجموعة بيانات الاختبار**: وهي مؤلفة من 33 تسجيلاً (كافة الصفوف متضمنة).

كما تم أيضاً تخفيض مقاييس (أحجام) التخمين بسبب تعقيد المسائل، حيث كان هناك 15 تصنيفاً بشكل أساسي. المعلومات الكاملة حول مقاييس التخمين يمكن إيجادها في الملحق. وقد خُفضوا بشكل نهائي إلى ستة أبعاد بضرب التخمينات التالية في مجموعة واحد:

AA^+, AAA – صكوك الأمان الأعلى.

AA^-, AA – صكوك أمان عالي.

A^-, A, A^+ – صكوك أمان كافية.

BBB^-, BBB, BBB^+ – صكوك أمان معتدلة.

BB, BB^+ – صكوك أمان نافضة (غير كافية).

D, C, B – صكوك مخاطرة عالية (صكوك خردة).

الطرق

تقنية تخفيض البُعدية

بغية تخفيض البُعدية للمسألة، قمنا باستخدام تحليل مكونات رئيسية (PCA) (Everitt & Dunn, 2001; Maddala, 1997). يتضمن PCA إجراءً رياضياً، يحول عدد من

المتغيرات المرتبطة (الممكنة) إلى عدد (أصغر) من المتغيرات غير المرتبطة تدعى بالمكونات الرئيسية. يفسر المكون الرئيس الأول أكبر قدر ممكن من التغير في البيانات. ويفسر كل مكون تالٍ أكبر قدر ممكن من التغير الباقي. وطُبق ذلك على جميع المتغيرات الـ 45. تم اختيار المكوِّنات اعتماداً على قيمها الخاصة (اختيرت مكونات بقيم خاصة أكبر من المعدل). تغطي هذه المكونات تقريباً أكثر من 5% من التفاوت (التغيرات) في العينات.

تقنية المتغير المخفض

في هذه التقنية خفض اختبار -t على تراجع خطي متعدد متغيرات الدخل من 45 إلى 20. كانت تلك المتغيرات الـ 20 هي التي لديها معاملات أكبر من 0.3. قائمة بهذه المتغيرات الهامة مبينة في (الجدول 3).

منهجية الحل النسبي (المقارن)

استخدامنا طريقة تراجع خطي متعدد (Maddala, 1997) على البيانات الأصلية بالإضافة إلى مكونات من تحليل المكونات الرئيسية لتوقع التخمين ومقارنته بالنتائج الأصلية المكتسبة من النموذج العائم والشبكة العصبونية العائمة. دقة العصبة الصارمة والأخفض المحافظة (CLB) معطية بالنسب المئوية. الدقة الصارمة (SA) – هي النسبة المئوية للصفوف، حيث يتطابق التخمين المتوقع تماماً مع التخمين المعطى. العصبة الأقل المحافظة (CLB) – هي النسبة المئوية للصفوف، حيث يهبط خرج النظام على الأغلب مستوى واحداً تحت التخمين الفعلي. وهذا هام لأن خسارة توقع صك ذي تخمين منخفض كمستوى عالٍ أكبر بكثير من خسارة توقع صك ذي تخمين عالٍ كمستوٍ منخفض.

الجدول (3) مجموعة مخفضة من المتغيرات

معدل المدينين/معدل الممتلكات الحالية	معدل رأس المال العامل/كامل الممتلكات
الربح قبل إيراد السهم المالي/ معدل رأس المال المستخدم	المبيعات/كامل الممتلكات
المبيعات/رأس المال المستخدم	الحجوزات/كامل الممتلكات
ربح تشغيل/مبيعات	الأرباح النقدية/كامل الاقتراضات
معدل الجرد/معدل الممتلكات الحالية	معدل نقد مصرف/معدل الممتلكات الحالية
معدل نقد مصرف/الممتلكات الحالية	الممتلكات الحالية/المبيعات
الممتلكات الحالية/كامل الممتلكات	كامل الممتلكات
المبيعات	العمر
كامل الاقتراضات/كامل الممتلكات	الدخل الكامل/قيمة الربح الصافي
الممتلكات الحالية/المسؤوليات القانونية الحالية	الممتلكات السريعة/كامل الممتلكات

النتائج والتحليل

تقنية تخفيض البُعدية

يعطي (الجدول 4) خلاصة النتائج الأفضل المُكتسبة من اختبار (تجريب) التوليفات المختلفة لبنى هندسية متنوعة. وقد أخذنا بالاعتبار ثلاثة أنواع من الشبكات غير المُراقبة هي: شبكة Kohonen، وسيلة -C العائمة، وشبكة Kohonen العائمة. ووجدنا النتائج الأفضل بالتقنية العصبونية العائمة.

تقنية تخفيض المتغير

يعطي (الجدول 5) خلاصة النتائج الأفضل المُكتسبة من اختبار (تجريب) التوليفات المختلفة لبنى هندسية متنوعة. وقد أخذنا بالاعتبار ثلاثة أنواع من الشبكات غير المُراقبة هي شبكة Kohonen وسيلة -C العائمة، وشبكة Kohonen العائمة. ووجدنا النتائج الأفضل بالتقنية العصبونية العائمة.

تفاوتت الدقة الصارمة من 33% من أجل شبكات SOFM إلى 51% من أجل شبكة Kohonen العائمة. كما تفاوتت الدقة الصارمة من 48% لشبكات التراجع الخطي إلى 62% لشبكة Kohonen العائمة. تتفوق تقنية الشبكات العصبونية والتقنية العائمة أداءً على الطرق الإحصائية العادية. مع ذلك، فإن دقة العصبية المحافظة هي تقريباً نفسها لجميع الشبكات.

الجدول (4) تقنية تخفيض البُعدية

البنية الهندسية	SA	CLB
SOFM	33	79
وسيلة C العائمة	47	79
شبكة Kohonen	51	80
تراجع خطي	45	76

الجدول (5) تقنية تخفيض المتغير

البنية الهندسية	SA	CLB
SOFM	52	76
وسيلة C العائمة	55	81
شبكة Kohonen	62	80
تراجع خطي	48	76

مقارنة بين تقنية تخفيض البُعدية وتقنية تخفيض المتغير

يمكننا من (الجدول 5) ملاحظة أن تقنية تخفيض المتغير تعطي دقة صارمة أفضل عبر بنى هندسية مختلفة. يتفوق أداء تقنيات تخفيض المتغير بالكامل على أداء تقنية تخفيض البُعدية. كما يمكننا أيضاً أن نلاحظ بأن النظام العصبوني العائم يعمل بشكل جيد في كلا التقنيتين. إن جوهر الأنظمة الذكية المصممة من هذا النوع هو أن تميز الشبكات العصبونية الأنماط، وتكّيف نفسها للتغلب على البيئات المتغيرة، وتدمج أنظمة الاستدلال والاستنتاج العائمة المعرفة البشرية، وتقوم بعملية الاستنتاج، واتخاذ القرار. الشيء المهم حول عناصر الأنظمة الهجينة هي أنها تكاملية وليست تنافسية مقدمةً ميزاتها الخاصة والتقنيات إلى الشراكات للسماح بحل مسائل المستحيلة الحل عادةً.

استنتاجات

أسسنا في هذا الفصل بنجاح تقنيات الحساب الناعم لتوقع تخمينات الصكوك. وقد وجدنا بأن الأنظمة العصبونية العائمة تفوق أداءً أنواعاً أخرى من الشبكات. مع ذلك، فإن أحد القيود الرئيسية لمثل هذه التقنيات هي عدم قدرتها على شرح سلوكها. فمن الصعب – على سبيل المثال – شرح الأهمية النسبية للمدخلات المتنوعة. يُنفذ غالباً تحليل حساسية الوزن لتطوير فهم سلوك النموذج. مع ذلك، لم نقم بتحليل حساسية الوزن. وهذا يشكل الأساس لصياغة القواعد، التي يمكن أن تُطبق في شكل من الشبكات المُراقبة. الغرض المستقبلي للعمل هو تطوير نوع من الأساس القواعدي باستخدام خبرة محللين لتشكيل توقعات دقيقة. وهذا يمكن تحقيقه بدمج أنظمة استنتاج استدلال عائمة (Takagi & Sugeno, 1985) داخل تعلم الشبكات العصبونية.

المراجع

Ball, G.H., & Hall, D.J. (1967). A clustering technique for summarizing multivariate data. Behavioral Science, 12, 153-155.

Deb, K. (2001). Multi-objective optimization using evolutionary algorithms. New York: John Wiley & Sons.

Bezdek, J.C. (1981). Pattern recognition with fuzzy objective function algorithms. New York; London: Plenum Press.

Bezdek, J.C., & Pal, S.K. (1992). Fuzzy models for pattern recognition. New York: IEEE Press.

Chaveesuk, R., Srivaree-ratana. C., & Smith, A.E. (1999). Alternative neural network approaches to corporate bond rating. Journal of Engineering Valuation and Cost Analysis,2(2),117-131.

Everitt,B.S., & Dunn, G. (2001). Applied multivariate data analysis (2nd ed.). Arnold.

Hassoun, M.H. (1995). Fundamentals of artificial neural networks. Cambridge, MA: MIT Press.

Kohonen, T. (1989). Self-organization and associative memory (3rd ed.). Berlin, Heidelberg; New York: Springer Verlag.

Maddala, G.S. (1997). Econometrics. McGraw Hill.

Manuj, H.K. (1993). An evaluation of the statistical properties of financial ratios. Ph.D. thesis. Indian Institute of Management Calcutta.

Mehrotra, K., Mohan, C.K., Ranka, S., & Mohan, C.K. (1997). Elements of artificial neural networks. Penram International Publishing.

Rating Scan. (1999). CRISIL, August.

Refenes, Apostolos-Paul. (1994). Neural networks in the capital markets. New York: John Wiley & Sons.

Sehgal, K.S., Ramasubramanian,G.S.,& Rajesh, K.M. (2001). Application of fuzzy table look-up method to credit rating. Euro Summer Institute XIX on Decision Analysis and Artificial Intelligence, Toulouse, France.

Takagi, T., & Sugeno, M. (1985). Fuzzy identification of systems and its application to modeling and control. IEEE Transactions on System, Man, Cybernetics, 15(1), 116-132.

Tsao, E.C.-K, Bezdek, J.C., & Pal, N.R. (1994). Fuzzy Kohonen clustering networks. Pattern Recognition, 27(5), 757-764.

Wang, L. (1997). A course in fuzzy systems and control. Prentice-Hall.

الملحق

AAA (الأمان الأعلى)	حُكم لتقديم الأمان الأعلى من الدفع في حينه للفائدة والأساس. مع ذلك، فإن الظروف التي تزود هذه الدرجة من الأمان من المحتمل أن تتغير. هذه التغيرات التي يمكن أن تتصور هي بشكل بعيد الاحتمال جداً من أن تؤثر بشكل عكسي على الموقع القوي أساساً لمثل هذه السندات.
AA (أمان عالي)	حُكم لتقديم أمان عالٍ من الدفع في حينه للفائدة والأساس وتختلف في الأمان عند سندات AAA فقط حدياً.
درجات الاستثمار A (أمان كافي)	حُكم لتقديم أمان كافٍ من الدفع في حينه للفائدة والأساس. مع ذلك، فإن التغيرات في الظروف يمكن أن تؤثر بشكل عكسي على مثل هذه السندات أكثر من تلك الموجودة في الأصناف المُقدرة بشكل أعلى.
BBB (أمان معتدل)	حُكم لتقديم أمان معتدل للدفع في حينه للفائدة والأساس الموجود. مع ذلك، التغيرات في الظروف هي على الأرجح ستؤدي إلى المقدرة الضعيفة لدفع الفائدة، وإعادة دفع الأساس أكثر من السندات المُقدّرة في فئات أعلى.
الدرجات التضاربية BB (أمان غير كافٍ)	حُكم لِحمل أمان غير كافٍ للدفع في جنيه للفائدة والأساس. عندما يكون أقل حساسية للتخلف حتى لسند درجات تخمين أخرى في المستقبل القريب، فإن الشكوك التي يواجهها المصدر، قد تؤدي إلى قدرة غير كافية للقيام بالدفعات في حينها.
B (مخاطرة عالية)	حُكم لامتلاك حساسية أكبر للتخلف عندما تواجه الفائدة والأساس بشكل آني، فإن العمل المقابل أو الظروف الاقتصادية ستؤدي إلى فقدان أو القدرة أو الرغبة في تسديد الفائدة أو الأساس.
C (مخاطرة كبيرة)	حُكم لامتلاك عوامل حالية التي تجعلهم عرضة للتقصير يكون من الممكن الدفع في حينه إذا استمرت الظروف المناسبة.
D (التخلف)	أثناء التخلف، وأثناء المتأخرات لدفعات الفائدة أو الأساس، أو متوقع التخلف على استحقاق الدين. تخميني للغاية ـ قد تدرك العائدات فقط بإعادة التنظيم أو التصفية.

يمكن أن تطبق إشارة (+) أو (-) للتقديرات من AA إلى C لعكس المكانة النسبية داخل تلك الفئة.

الفصل الحادي عشر

توقع تخمينات الائتمان بهجين من GA-MLP

ملخص

إن التطبيق العملي لشبكات MLPs يمكن أن تكون استهلاكاً للوقت بسبب متطلب التدخل الكبير لمصمم النموذج كي يختار المدخلات والبارامترات المناسبة من أجل MLP.

يدرس هذا الفصل مثالاً على كيف يمكن لعناصر من مهمة بناء MLP أن تكون مؤتمتة بواسطة خوارزمية تطورية. طُوّرت شبكة MLP، التي تكون مدخلاتها وبنيتها مختارة آلياً باستخدام خوارزمية وراثية (GA) بغية توقع تخمينات مُصدّر صكوك متعلقة بالشركات. تقترح النتائج بأنه يمكن للنموذج المُطوّر أن يتوقع بدقة تخمينات الائتمان المعينة لمصادر صكوك.

مقدمة

يشرح هذا الفصل قدرة شبكة perceptron متعددة الطبقات المدربة بالانتشار الخلفي (MLP) على نمذجة عملية تخمين ائتمان مصادر الصكوك المتعلقة بالشركات بدقة. بالرغم من أن MLPs قد طُبقت بشكل واسع على مسائل واقعية، فإن تطوير نموذج MLP نوعي من أجل مهمة معينة، يمكن أن يكون مستهلكاً للوقت، بما أنه يجب على مصمم النموذج أن يقرر أي المدخلات ستستخدم، وما هي البنية الهندسية الداخلية التي ستستعمل في MLP.

في التطبيق (في هذا الفصل) تُستخدم الخوارزمية التطورية (الخوارزمية الوراثية) لأتمتة مكونات تلك المهام. تجمع أكثر الشركات الكبيرة كلاً من رأسمال الدين والسهم لتزويد التمويل الطويل الأمد لعملياتها. قد يعطى الرأسمال من قبل بنك ما، أو يمكن الحصول عليه ببيع الصكوك مباشرة إلى المستثمرين. وكمثال، مقياس أسواق الصكوك الأمريكية، حيث أن قيمة الصكوك الصادرة في الربع الأول من العام 2003 كان ما مجموعة 1.70 تريليون دولار (إحصائيات سوق الصكوك

لعام 2003). عندما تريد شركة متاجرة عامة، أن تصدر دين متاجرة أو صكوك (يعرف الصك مثل كفالة أو سند دين يشكل وعداً من قبل الشركة الصادرة لدفع معدل الفائدة المذكور مستنداً إلى القيمة الظاهرية للصك، واسترداد الصك في هذه القيمة الظاهرية عند استحقاق الدين). ويجب الحصول على تخمين ائتمان للإصدار من وكالة تخمين واحدة على الأقل معترف بها مثل وكالة Standard & Poor (S&P) أو Moody أو Fitches. يمثل تخمين الائتمان رأي وكالة تخمين في تاريخ معين لاستحقاق الائتمان لمقترض في العموم (المعروف لتخمين ائتمان صادر)، أو في احترام إصدار دين معين (تخمين ائتمان صك). يخدم التخمين كإجراء بديل لمخاطرة عدم تسديد الفائدة أو عدم إعادة دفع رأسمال صك ما.

قد تهتم عدة فئات من الأشخاص في نموذج يستطيع إعطاء تقديرات دقيقة لتخمين الصكوك. سيكون لمثل هذا النموذج اهتمام من الشركات، التي تعتبر أن إصدار الدين سيمكّنها من تقدير المتطلب للعودة المحتملة للمستثمرين، فيما يتصل بذلك بتزويد معلومات عن تسعير صكوكها. كما يمكن أن يُستخدم النموذج لتقييم اعتماد الشركات، التي لم تصدر ديناً. وبالتالي، لا تملك تخمين صك منشور أو مُعلن. قد يكون ذلك مفيداً للمصرفين أو لشركات أخرى الذين يدرسوا فيما إذا كان عليهم منح الائتمان لتلك الشركة. الدين المُقدّر الكبير هو عام في سوق الأسهم المالية، بينما تخمينات الصكوك فهي تتغير نموذجياً بشكل نادر. يمكن أن يشير نموذج توقع تخمين صكوك دقيق فيما إذا كان التخمين الحالي لصك ما مازال مبرراً. إلى حد أنه يمكن لمستثمر فردي أن يتوقع إعادة تخمين صك ما قبل أن يتوقعه مستثمرون آخرون. وهذا قد يزود حافة تجارية.

دوافع الدراسة

يوجد عدد من الأسباب للافتراض بداهةً، بأن توليفة الخوارزمية الوراثية مع MLP، يمكن أن تُجرب بشكل مثمر في توقع تخمين الصكوك المُصدر. إن مجال التطبيق موصوف بالافتقار إلى إطار عمل نظري قوي، ويملك متغيرات توضيحية ذات تعدد معقول وتفاعلاً كافياً. المشكلة الأولى التي تواجه مصمم النموذج هي اختيار مجموعة جزئية جيدة من تلك المتغيرات. وتكمن المشكلة الثانية في اختيار شكل نموذج مناسب. وهذا الأمر في تطبيقات MLPs، لا يكون مهمة عاديةً، بما أن العديد من الاختيارات مفتوحةً أمام مصمم النموذج متضمنة طبيعة البنية الاتصالية، وشكل تابع التفعيل في كل عقدة، واختيار خوارزمية التعلم والبارامترات المرافقة لها. يمثل اختيار المتغيرات التوضيحية النوعية وشكل النموذج مسألة ائتلافية عالية البُعدية معطيةً الإمكانية المنهجية التطورية، التي يمكن أن تؤتمت هذه العملية (Mitchell, 1996). لدى مثل هذه المنهجيات المؤتمتة قدرة واضحة للامتداد إلى تنوع تطبيقات التنقيب في المعطيات. حتى الوقت الحاضر، طُبق عدد محدود

نسبياً من الدراسات المنهجية التطورية – بما فيها الخوارزميات الوراثية (GA)، والبرمجة الوراثية (GP)، والتطور القواعدي (GE) – في مجال توقع تخمين الصكوك أو المجال المتعلق بالتوقع الفاشل للشركات (Back, Laitinen, Sere, & Van Wezel, 1996 ،Varetto, 1998; Kumar, Krovi & Rajagopalan 1997، Brabazon & O'Neill, 2003). يعالج هذا الفصل تلك الفجوة.

بنية الفصل

بنية هذا الفصل منظمة كالتالي: يزود القسم القادم مراجعة مختصرة لعملية تخمين الصكوك، وللمادة المنشورة سابقاً المتعلقة بتوقع تخمين الصكوك. ثم يتبعه قسم يقدم GA، ويصف كيف يمكن دمج منهجيات MLP وGA. بعد ذلك، يتم وصف مجموعة المعطيات والمنهجية المستخدمة. تبين الأقسام الباقية نتائج التجارب، يتبعها عدد من الاستنتاجات والمقترحات للعمل المستقبلي.

تخمين الصكوك

بالرغم من أن التدوين الدقيق المُستخدم من قبل وكالات التخمين الفردية للدلالة على استحقاق ائتمان صك ما أو مصدّر يتفاوت، ففي كل حالة يُدّل على التخمين بشكل أساسي بواسطة حرف. بأخذ بنية تخمين وكالة S&P كمثال، فإن التخمينات مُخفضة إلى 10 صفوف واسعة انظر (الجدول 1). التخمين الأقوى مُرمّز بـ AAA، ثم تنخفض التخمينات بالترتيب التالي: AA، A، BBB، BB، B، CCC، CC، C، D. وبالتالي، تُنقل التخمينات بواسطة درجة حرفية منفصلة بتبادلية خاصة. تُدرس التخمينات بين AAA وBBB (ضمناً) من قبل المستثمرين لتمثيل تخمينات درجة الاستثمار، وبتخمينات أقل جودةً مُعتبرة لتمثيل الدين تصدر بمواصفات مُضاربة هامة أو مواصفات مخاطرة، تُعرف صكوك درجة الاستثمار الجزئية "بصكوك الخردة". يمثل تخمين درجة C الحالة، حيث تُحفظ عريضة إفلاس، ويمثل تخمين D الحالة حيث يكون المقترض التخلف عن الالتزامات المالية. يمكن أن تُعدل التخمينات من AAA إلى CCC بإضافة إشارة (+) أو (-) للإشارة لأي نهاية فئة يهبط تخمينها.

عملية تخمين الصكوك

تكسب وكالات التخمين الأجور من مصدري الصكوك لتقييم حالة الائتمان لصكوك جديدة، ومن أجل المحافظة على تغطية تخمين ائتمان هذه الصكوك. تحصل أي شركة على تخمين ائتمان لإصدار دين بالاتصال بوكالة تخمين، وطلب بأن يكون تخمين الإصدار مخصصاً للدين الجديد، أو أن يكون التخمين المُصدّر الكلي مخصصاً للشركة. كجزء من عملية الحصول على تخمين،

تقدم الشركة وثيقة تتضمن البيانات المالية الحالية، ونشرة تمهيدية لإصدار الدين، ومعلومات أخرى غير مالية. تجري المناقشات بين وكالة التخمين وإدارة الشركة. ثم يُحضر بعد ذلك تقرير تخمين من قبل محللي ائتمان بفحص الشركة، ثم يُدرس تقرير التخمين هذا من قبل لجنة في وكالة التخمين، التي تقرر بأن يكون تخمين الائتمان مُخصصاً لإصدار الدين أو للمصدر. تؤكد وكالات التخمين، بأن عملية تخمين الائتمان تتضمن الاعتبارات المالية بالإضافة إلى معلومات غير مالية عن الشركة.

الجدول (1) درجات حرفية للتخمين لوكالة Moody ووكالة S&P

Moody	S&P	تعريف
تخمين		
Aaa	AAA	أفضل نوعية بالدرجة الصغرى لمخاطرة الاستثمار. مشار إليها كـ (صكوك من الدرجة الأولى).
Aa	AA	نوعية عالية مقدرة أقل من AAA كهوامش حماية للدائن. وهي ليست عالية كما هو الحال من أجل AAA.
A	A	التزامات الدرجة المتوسطة العليا - أكثر عرضةً لتغير الأحوال الاقتصادية .
Baa	BBB	التزامات الدرجة المتوسطة - لا محمية جداً ولا مضمونة بشكل سيئ.
	BB	دين تخميني بكفالة معتدلة. حماية تسديدات الفائدة والأساس ليست مصانة بشكل جيد.
B	B	له خطر بارز في التخلف مستقبلاً. درجة محدودة للتأمين يما يتعلق بتسديدات الفائدة والأساس.
Caa	CCC	صكوك نوعية رديئة مع مواصفات خطر كبير.
Ca	CC	صكوك باحتمال عالٍ جداً للتخلف.
C	C	صكوك صادرة من قبل الشركات التي هي في حالة إفلاس.
	D	الصكوك التي هي في حالة تخلف.

وتشير إلى أن عملية التخمين تعتبر أيضاً العوامل الصناعية ومستوى التسويق. إن العوامل الدقيقة والتثقيل المتعلق بتلك العوامل غير مكشوف عنها علناً من قبل وكالات التخمين.

لاحقاً، لتخمينها الأولي قد يُعاد تخمين صك ما أو مُصدّر للأعلى (يرتفع إلى درجة أعلى)، أو للأسفل (يخفض إلى درجة أسفل)، إذا تغيرت الشركة أو الظروف البيئية. إن إعادة تخمين صك من درجة استثمار إلى حالة صك الخردة - كالصكوك المعروفة بالملاك الساقط - قد تسبب تصفية هامة. يُسمح للعديد من المستثمرين المؤسساتيين فقط بالتعليمات الخارجية أو المفروضة ذاتياً للتمسّك بصكوك درجة الاستثمار.

إن التأثير العملي لصك (أو مُصدّر) معين تخمين أقل بدلاً من تخمين أعلى هو زيادة مخاطرته المحسوسة في عيون المستثمرين المحتملين. وبالتالي، يرتفع عائد الفائدة المطلوبة. وكتوقع لهذا، التفاضل فإن انتشار التخمين بين درجة الاستثمار وصكوك الخردة يُتوقع بحوالي 5 نقاط (Business Week, 2003). بالإضافة إلى التأثير على عائد الفائدة لصك ما، فإن تخمين الائتمان المُعين أيضاً يؤثر على إمكانية تسويق صك ما.

توقع تخمين الصكوك

إن الغرض من المادة المنشورة حول توقع تخمين الصكوك هو بناء نموذج لسلوك وكالة التخمين باستخدام معلومات عامة متوفرة. يوجد حجم كبير من المادة المنشورة حول توقع تخمين الصكوك. استخدمت المحاولات الأسبق منهجيات كلاسيكية كتراجع خطي (OLS) (Horrigan, 1966; Poque & Soldofsky, 1969)، تحليل مميز متعدد (Pinches & Mingo, 1973)، نموذج منطقي متعدد الأسماء (Ederingdon, 1985)، وتحليل وحدة الاحتمالية المرتبة (Gentry, Whitford & Newbold, 1988). تتفاوت النتائج من تلك الدراسات، وتم الحصول نموذجياً على حوالي 60 إلى 70% دقة توقع (خارج العينة) عند التمييز بين تخمينات درجة الاستثمار/غير الاستثمارية باستخدام معطيات مالية كمدخلات. بحلول الذكاء الصنعي وتعلّم الآلة توسعّ مجال التقنيات المطبقة لتوقع تخمين الصكوك ليشمل الشبكات العصبونية (Maher & Sen. 1997)، والطرق المعتمدة على الحالة (Shin & Han, 2001)، وآليات شعاع الدعم (Huang, Chen, Hsu, Chen, Wu, 2004). في حالة البحث السابق للشبكات العصبونية، تفاوتت الدقة التنبؤية للنماذج المُطورة. استخدمت دراسات عديدة هدفاً تنبؤياً ثنائياً، وأُبلغ عن دقة تصنيف جيدة. على سبيل المثال، استخدم العالمان Dutla وShekhar (1988) شبكة عصبونية لتوقع تخمين صكوك AA أو غير AA، وحصلا على دقة مقدارها حوالي 83.3%، استعملت هذه الدراسة حجم عينة صغير (47 شركة). والمسألة الأكثر صعوبة هي توقع التخمين الدقيق لأي صك من التخمينات الممكنة المتعددة، التي يمكن أن تُخصصها وكالة تخمين ما. أنتجت وكالة Moody وUtans (1995) دقة تنبؤية بحوالي 36.2% في 16 حالة تخمين، والتي تتحسن لتصبح 63.8%، عندما يُخفض عدد التخمينات إلى خمس حالات. لسوء الحظ، لم تكشف الدراسة لا غن حجم العينة، ولا عن متغيرات دخل النموذج جاعلةً من الصعب تصميم إمكانية تعميمها.

تحمل مهمة التنبؤ بتخمين ائتمان صكوك المصّدر تشابهاً بارزاً إلى مشكلة تنبؤ الفشل المتعلقة بالشركات المشهورة. في كل مجال، يكون الغرض المفتاحي هو استباق المحنة الحالية. لقد أشار البحث السابق الذي درس فشل الشركات بقوة إلى أن تلك النماذج، التي تستخدم معطيات مالية كمدخلات، قادرة على توقع فشل الشركات قبل عدة سنوات من حدوثه (Altman, 1993،

(Brabazon & Keenan, 2004). وهذا يقترح بأنه من المعقول افتراض أن المعطيات المستخلصة من البيانات المالية لشركات صادرة للصكوك، قد تعطي دخلاً مفيداً إلى نموذج توقع تخمين الائتمان من أجل تلك الشركات.

الخوارزمية الوراثية

بالرغم من تطوير عهود GA منذ الستينات، فقد كان العالم Holland (1975) أول من لفت انتباه الجمهور العريض إليها. تم تطبيق GAs في تشكيلة من أماكن الأعمال متضمنةً المجال المالي (Bauer, 1994, Deboeck, 1994, Varetto, 1998)، وعدة فروع من علم الإدارة كإدارة الجرد (Sarker & Newton, 2002)، وتوجيه عربة (Baker & Ayechew, 2003). يمكن أن تعتبر GA كخوارزمية أَمْثَلة رياضية، تكون طرق عملها مُلهمة مجازياً بنظرية التطور لداروين. تتخذ GA وحدة مجتمع للتحليل، وكل عنصر من المجتمع يوافق ترميزاً لحل ممكن للمسألة المدروسة. تقليدياً، كانت الترميزات (أو الأنماط الوراثية) عبارة عن سلاسل ثنائية (0، 1، 0، 1، ...)، بَيْدَ أنه يمكن أن تعمل GA على ترميزات بأعداد صحيحة أو حقيقية. يمكن أن تُفسر الأنماط الوراثية (أو يُفك ترميزها) بطرق متنوعة جداً اعتماداً على طبيعة المسألة. على سبيل المثال، يمكن أن يُفسر نمط وراثي لإنتاج حل مسألة (نمط ظاهري) كمعاملات من أجل نموذج التراجع انظر (الشكل 1)، أو قاعدة التصنيف، أو جدول الإنتاج، أو بنية MLP. تُحدد جودة كل نمط ظاهري بالاستناد إلى تابع ملاءمة معين للمسألة. يُقلّد التطور في مجتمع الأنماط الوراثية بواسطة عملية اختيار طبيعية زائفة باستخدام اختيار ملاءمة تفاضلي، ومعاملات وراثية زائفة لأحداث التغيرات في المجتمع بين الأجيال المتعاقبة. ومن الهام ذكر أن العملية التطورية لـــ GA تعمل على الأنماط الوراثية بدلاً من العمل مباشرة على الحلول نفسها.

عموماً يمكن أن تُوصف الخوارزميات التطورية المتضمنة لـــ GA القانونية كالآتي:

$$X[t + 1] = v (S (X[t]))$$

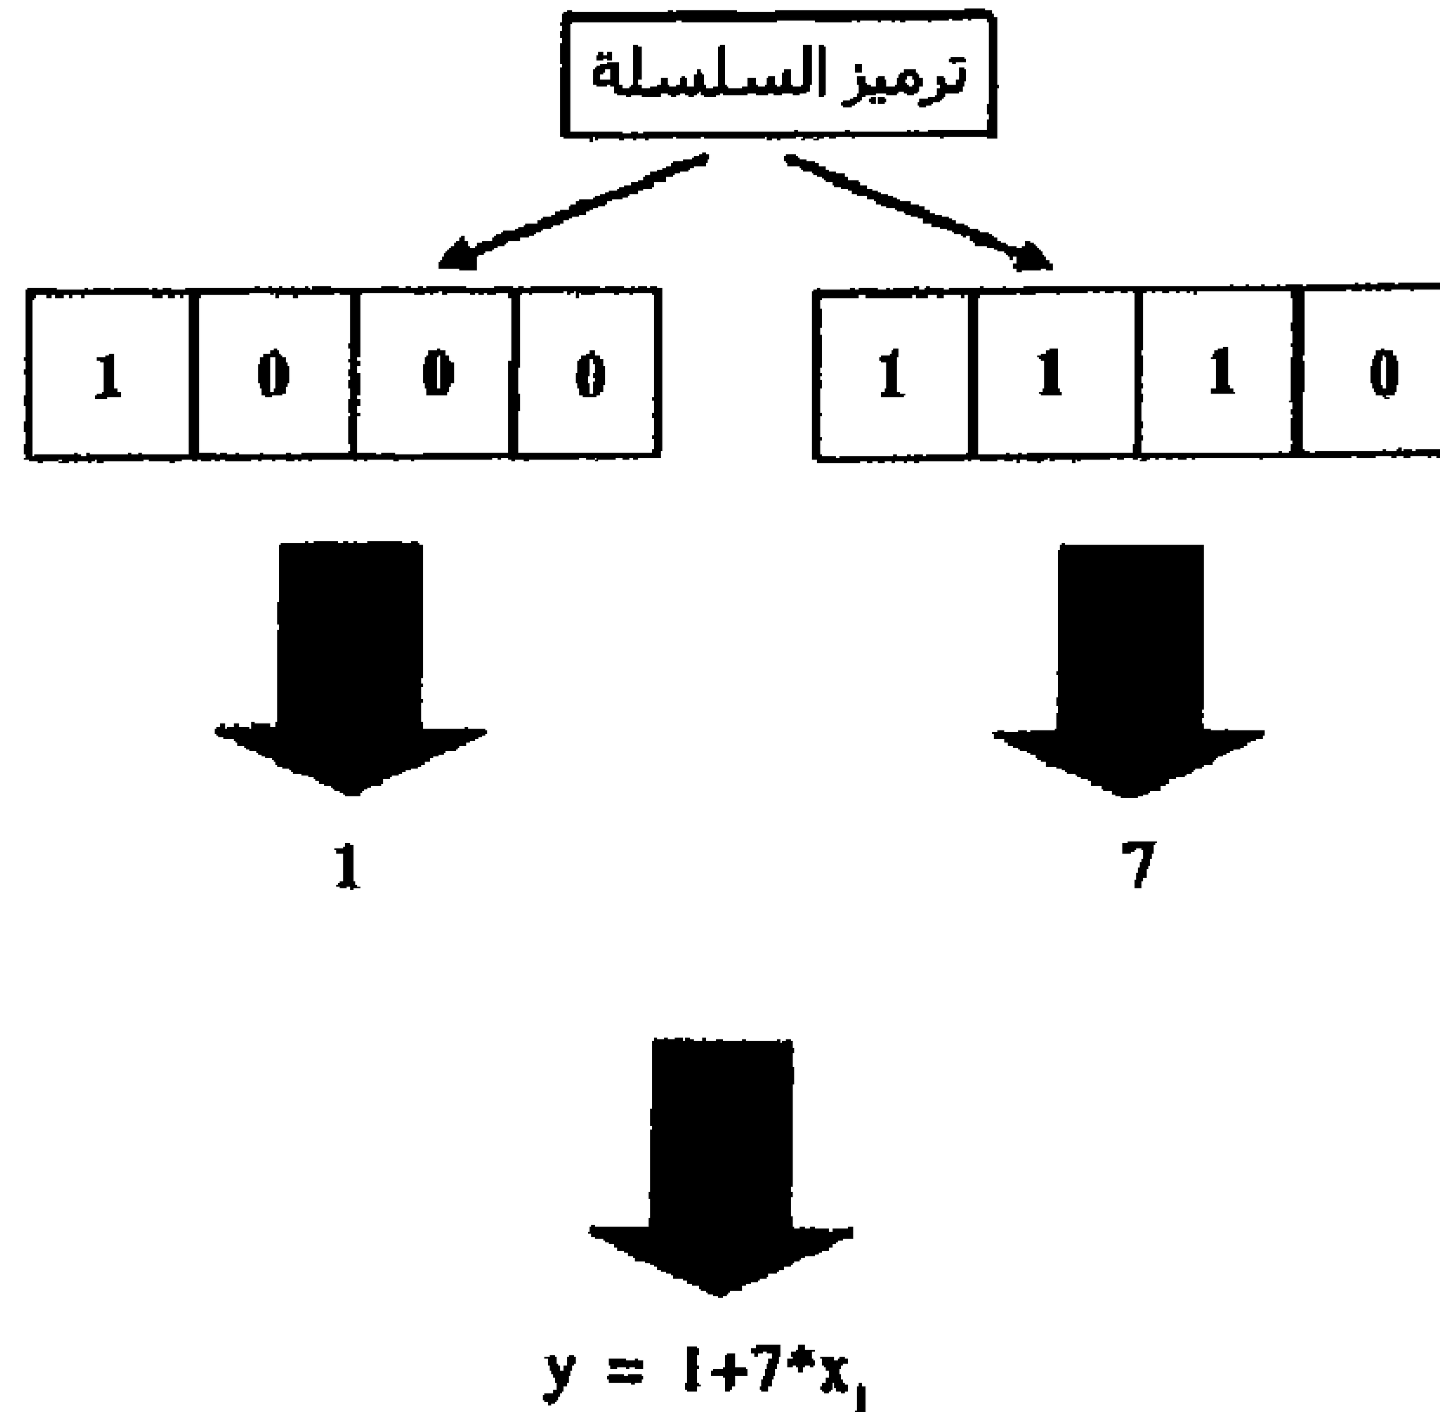
حيث أن:

X[t] – هو مجتمع الأنماط الوراثية في التكرار t.

v(.) – معامل تغير عشوائي (معاملات تصالب وطفرة).

S(.) – معامل اختيار.

الشكل (1) *مثال على كيف يمكن أن ترمز سلسلة ثنائية معاملين من أجل نموذج خطي. تُرمز السلسلة بدايةً في عددين صحيحين يُدخلا بعد ذلك في النموذج الخطي كمعاملات.*



وبالتالي، يمكن توصيف GA القانونية كخوارزمية اتفاقية تحول مجتمع واحد من الأنماط الوراثية إلى آخر باستخدام الاختيار، والتصالب، والطفرة. يستثمر الاختيار المعلومات في المجتمع الحالي مركزاً الاهتمام على أنماط وراثية ذات ملاءمة عالية. يقلق التصالب والطفرة تلك الأنماط الوراثية في محاولة لكشف الأفضل منها، ويمكن أن تعتبر هذه المعاملات كتجريبيات عامة من أجل الاستكشاف. يمكن أن تُصاغ GA كسلسلة ماركوفية ذات بُعد محدود، حيث توافق كل حالة منها شكل مجتمع من الأنماط الوراثية. اعتماداً على شكل المعاملات الوراثية المطبقة في الخوارزمية، سوف تتغير احتمالات الانتقال بين الحالات. في GA القانونية، يشير إدراج معامل طفرة إلى أنه لا توجد حالات ماصة في العملية الماركوفية، وأن كافة الحالات يمكن أن تحدث فعلياً.

تطبيق GA

بالرغم من أن GA يمكن أن تستعمل تشكيلة من الترميزات، فإننا نُركز على الترميز الثنائي في شرحنا لطرق عمل GA في هذه الفقرة الثانوية. ما أن يُشكل المجتمع الابتدائي من الأنماط الوراثية (ربما بشكل عشوائي)، وتُقيّم الملاءمة لأنماطها الظاهرية الموافقة، حتى تُطبق عملية التكاثر، التي تمتلك فيها الأنماط الوراثية الموافقة للأنماط الظاهرية الأفضل جودةً فرصاً أعلى لأن تُختار لنشر مورثاتها (الخانات) في الجيل التالي للأنماط الوراثية. خلال سلسلة من الأجيال، تتجه الأنماط الوراثية الأفضل - على شكل تابع ملاءمة معطى (محدد للمسألة) - إلى الازدهار في المجتمع، وتميل الحلول الأضعف للاختفاء.

تؤمن مرحلة التكاثر محركاً لعملية البحث، حيث يُحيِّز عملية البحث باتجاه الأنماط الوراثية الموجودة عالية الجودة، ويستخدم المعلومات لقيادة فضاء البحث، تُحكم عملية التكاثر عموماً بعاملين: التصالب والطفرة (Mitchell, 1996). يأخذ معامل التصالب نمطين وراثيين من المجتمع، ويبدل أجزاء مكونة لكل منهما بغية خلق أعضاء ممكنة للتوليد التالي للمجتمع. لنفترض مثلاً أنه تم اختيار نمطين وراثيين أبوين يملكان السلاسل الثنائية التالية: (001101) و(11001100). يسبب معامل الطفرة تغيرات عشوائية صغيرة في مورثة واحدة أو أكثر من حل الابن. وبتمثيل ثنائي يمكن أن يتغير 0 إلى 1 أو 1 إلى 0. تُقيّم التوليدات المتعاقبة للأنماط الوراثية، وتُختار للتكاثر بالاعتماد على ملائمتهم التفاضلية، ومن ثم تُخضع لعملية تكاثر حتى يتحقق معيار توقف محدد مسبقاً.

مخطط عمل GA قانونية (Goldberg, 1989) هو الآتي.

1. بدء مجتمع من الأنماط الوراثية.
2. تقييم كل نمط وراثي في المجتمع بتطبيق تابع موضوعي لحل موافق له (نمط ظاهري).
3. اختيار أنماط وراثية عالية الملاءمة لتكون آباء في خلق أنماط وراثية جديدة.
4. خلق أنماط وراثية جديدة بتطبيق التصالب والطفرة.
5. إزالة أعضاء من المجتمع الحالي لفسح المجال للأنماط الوراثية المُخلّقة حديثاً.
6. تقييم كل نمط وراثي في المجتمع بتطبيق تابع موضوعي لحل موافق له (نمط ظاهري).
7. إذا تم تحقيق معيار التوقف، يتم التوقف وإعادة النمط الوراثي بالملاءمة الأفضل، وإلا تتم العودة إلى الخطوة 3.

دمج منهجيات GA وMLP

على الرغم من الاختلافات الظاهرة بين منهجيات GA وMLP، فإنه يمكن أن يتمما بعضهما البعض بشكل مفيد بدمج مقدرات النقل غير الخطية لـــ MLP مع مقدرات الأَمْثلة لـــ GA. على سبيل المثال، يمكن أن تُستخدم GA لاختيار واحدة من الأمور التالية أو كلها:

- اختيار مدخلات النموذج.
- عدد العقد في كل طبقة خفية.
- طبيعة توابع التفعيل في كل عقدة.

- شكل خوارزمية التعلم وبارامتراتها المرافقة.
- عدد الطبقات الخفية.
- أوزان الاتصال بين كل عقدة.

عند تطوير MLPs باستخدام GA، تكون الخطوة الأولى هي تحديد كيف يتم فك ترميز النمط الوراثي في MLP معينة. يمكن أن يرمز النمط الوراثي لـــ MLP باستخدام تمثيل ثنائي أو تمثيل ذي عدد صحيح أو حقيقي (أو مزيجاً معيناً من ذلك)، وسوف يمتلك شكل الترميز معاني متضمنة للتصميم المناسب لمعاملات التصالب والطفرة. هناك عدة طرق يمكن أن تُرمّز بها بنية MLP، وكذلك عدة أشكال مختلفة لـــ GA، يمكن أن تُطبق لتطوير تلك الترميزات. بأخذ مثال بسيط، نعتبر حالة حيث تستخدم GA لتطوير مدخلات وبنية MLP، ولا تُستخدم لتطوير أوزان اتصالات لهذه MLP.

يمكن أن تُعرف خوارزمية GA-MLP القانونية كالآتي:

1. فك ترميز النمط الوراثي إلى بنية MLP.
2. البدء عشوائياً بأوزان الأقواس في هذه البنية.
3. تدريب MLP باستخدام خوارزمية الانتشار الخلفي.
4. تحديد دقة التصنيف (الملاءمة) لـــ MLP الناتجة.
5. تنفيذ اختيار معتمد على الملائمة لخلق مجتمع جديد من الأنماط الوراثية.
6. خلق تنوع من الأنماط الوراثية للمجتمع الجديد باستخدام التصالب والطفرة.
7. استبدال المجتمع القديم بالمجتمع الجديد.
8. إعادة الخطوات السابقة حتى الوصول إلى معيار التوقف.

يمثل هذا مثالاً لـــ GA توالدية، حيث يُستبدل كامل المجتمع بآخر مُخلّق من جديد في كل تكرار للخوارزمية. إن استراتيجيات الاستبدال الأخرى، التي يمكن أن تُستخدم، تتضمن حالة مستقرة حيث يُستبدل فقط عدد صغير من السلاسل الفردية الأقل ملاءمة في المجتمع بحلول أخرى أفضل مُخلقة من جديد في كل توليد. كما يمكن أيضاً أن تُنفذ خطوة الاختيار في GA بتشكيلة من الطرق متضمنةً اختيار ملاءمة مناسب، واختيار مرتبةٍ أو اختيار بطولة (Mitchell, 1996).

تنتج التوليفة GA/MLP الموصوفة تعلماً ثنائي المستوي. يُرمّز اختيار المدخلات والبنية الهندسية لـــ MLP في بنية وراثية (سلسلة ثنائية مثلاً)، تُبدّل بمرور الوقت، عندما تفتش GA فضاء

السلاسل الثنائية بغية كشف السلاسل، التي تُرمّز أفضل MLPs. يمثل هذا تعلم تاريخ تطور السلالة (تعلماً وراثياً). من أجلِ كل بنية MLP متميزة تستخدم خوارزمية الانتشار الخلفي، لكي تكتشف الأوزان الجيدة ممثلةً تعلماً خارج وراثي (العمر) (Sipper & Sancher, 1997). من أجل مناقشة أكثر تفصيلاً للقضايا الظاهرة في دمج منهجيات GA وMLP ارجع إلى Yao (1999) وDorado, Santos, and Rabunal (200).

المنهجية

أجريت تجربتان. وقد اُستقصت بدايةً فائدة النموذج MLP/GA للتمييز بين تخمين صكوك ذات درجة استثمارية، وأخرى ذات درجة غير استثمارية. ثانياً، تم استقصاء قدرة النموذج MLP/GA لتوقع صفوف تخمين دقيقة لسلسلة من الصكوك. وفي هذا الفصل، حصرنا الدراسة في أربعة صفوف للصكوك A، BBB، BB، B.

مجموعة المعطيات

أثناء جمع المعطيات حُدّد الانتباه إلى شركات غير مالية بغية ضمان أن نسب المحاسبة المكتسبة كانت قابلة للمقارنة عبر الشركات. وطُبقت المعايير التالية للحصول على العينة النهائية:

1. يجب أن تكون معلومات المحاسبة وتخمينات المصدّر متوفرة من قاعدة بيانات وكالة S&P.
2. يجب أن يكون للشركات نهاية سنة مالية في 31 كانون الأول 2003.
3. يجب أنت يكون للشركات تخمين مصدّر طويل الأمد لـــ S&P في 31 كانون الأول 2003.
4. يجب أن تكون معطيات المحاسبة متوفرة لمدة ثلاثة سنوات قبل العام 2003 ضمناً.

ترك تحقيق المعايير عينة من 667 شركة بتخمينات مصدّر طويلة الأمد تتراوح منِ AAA وحتى D انظر (الجدول 2). تمت إزالة الشركات بتخمينات AAA وAA وCCC وCC وD نتيجةً للعدد القليل من الشركات، التي تملك هذه التخمينات، وبذلك أبقيت مجموعة معطيات نهائية من 632 شركة. تطلبت المرحلة التالية لاختيار العينة التقسيم العشوائي للشركات الباقية إلى مجموعة معطيات تدريب ومجموعة اختبار.

في حالة التوقع الثنائي (توقع درجة استثمار مقابل درجة غير استثمارية)، اُختيرت 460 شركة بشكل عشوائي من العينة الكلية لـــ 632 شركة لتشكيل مجموعتين من 230 تخمين درجة

استثمار و320 درجة استثمار جزئية. خُصصت 460 شركة بشكل عشوائي لمجموعة التدريب (320) أو عينة محتواة خارجاً (140) ضامنةً بأنه تمت موازنة كل مجموعة بالتساوي بين تخمينات درجة الاستثمار ودرجة غير استثمارية. في حالة التخمين المتعدد تمت موازنة مجموعة معطيات التدريب والمجموعة المحتواة خارجاً بين شركات مخمنة A، BBB، BB، B. ومن جديد بمجموعة تدريب من 320 عينة ومجموعة محتواة خارج العينة من 140. أُعيد تقطيع مجموعة معطيات الـــ 632 شركة سبع مرات بغية خلق سلاسل مجموعات تدريب ومجموعة خارج العينة.

الجدول (2) مجموعة معطيات تخمين مصدّر

	تخمين صكوك	عدد الصكوك
درجة استثمارية	AAA	6
	AA	13
	A	137
	BBB	206
درجة غير استثمارية	BB	172
	B	117
	CCC	12
	CC	2
	D	2
المجموع		667

اختيار متغيرات الدخل

وُجّه اختيار متغيرات الدخل من قبل المادة المنشورة على توقع الإفلاس والمادة المنشورة على توقع تخمينات الصكوك وبواسطة التحليل الإحصائي. إن العديد من الدراسات السابقة لتوقع تخمين الصكوك (Horrigan 1966، West, 1970، Pogue & Soldofsky, 1969، Pinches & Mingo, 1973، Dutta & Shekhar, 1988، Surkan & Singleton, 1990، Brennan & brabazon, 2004، Yesilyaprak, 2004)، وعدة دراسات على فشل الشركات تمت مراجعتها، وهي تنتج 54 متغيراً دخل محتمل. وقد حُدّد منها مجموعة من 20 متغير دخل محتمل متميز.

إن الهدف من اختيار مجموعة المتغيرات التوضيحية الأولية هو اختيار متغيرات مالية، تتفاوت قيمها بين الشركات في صفوف تخمين صكوك مختلفة، وحيث تُقلّل تداخلات المعلومات بين المتغيرات لتصبح أصغرية. باتباع تحليل إحصائي للنسب المالية، خُفضت مجموعة المدخلات المحتملة إلى 14 انظر (الجدول 3). أظهرت كافة النسب المختارة متوسطاً مختلفاً إحصائياً عند المستوى 1% بين فئات درجة الاستثمار/صكوك الخردة.

الجدول (3) متوسط النسب المالية المختارة من أجل مصدّر درجة الاستثمار والدرجة غير الاستثمارية .

	درجة استثمار	درجة غير استثمارية
الحجم		
سجل الممتلكات الكلية	3.748	3.2116
الربحية	0.048	0.0005
الدخل الصافي/الممتلكات الكلية	0.070	-0.115
الدخل الصافي/المبيعات	0.221	- 0.191 -
أرباح غير موزعة/الممتلكات الكلية	9.283	2.357
EBIT/الفائدة		
السيولة		
النسبة الجارية	1.492	2.099
رأس مال العامل/المبيعات	0.089	0.404
الفعالية		
دين طويل الأمد/الممتلكات الكلية	0.262	0.391
النشاط		
مبيعات/الممتلكات الكلية	0.757	0.873
الجرد/رأسمال العامل	0.358	0.573
الاستقرار		
[NM 2003/NM 2001] - 1	0.362	-0.573
[TA 2003/TA 2001] - 1	0.017	0.015
[CR 2003/CR 2001] - 1	0.123	0.292
[NI/TA 2003/NI/TA 2001] -1	0.248	-0.472

كما هو متوقع، فإن النسب المالية لتخمينات مصدّر درجة الاستثمار هي أقوى من النسب المالية لتخمينات صكوك الخردة. والاستثناء الوحيد هو النسبة الحالية التي هي أقوى من أجل شركات مخمنة صكوك الخردة التي من المحتمل أن تشير لتفضيل تلك الشركات لاكتناز السيولة قصيرة الأمد، عندما يكون وصولها إلى أسواق رأس المال طويل الأمد محدوداً.

بناء نموذج GA/MLP

بدايةً، تم عشوائياً توليد مجتمع من 50 نمط وراثي ثنائي كلٌّ منهم يوافق بنية MLP متميزة، ومجموعة من المتغيرات التوضيحية. صُمم النمط الوراثي لترميز مجال من البنى التي فيها:

- يمكن أن يتفاوت عدد المدخلات حتى قيمة عظمى مقدارها ثمانية.
- يمكن أن يتفاوت شكل تابع التفعيل لكل عقدة معالجة بين خطي ومنطقي.
- يمكن أن يتفاوت عدد عقد الطبقة الخفية حتى قيمة عظمى مقدارها أربعة.

أثناء تطوير النماذج فُرض بدايةً حد من أربعة عقد طبقة خفية وثمانية متغيرات دخل. كان الغرض من وضع هذه القيود على بنى الشبكات، التي تقوم بالبحث بواسطة العملية التطورية هو الحفاظ على درجات الحرية والتقليل من خطر الإفراط في الملاءمة. تمت المباشرة فيما بعد بسلسلة من التجارب لتحديد فيما إذا أثرت هذه القيود عكسياً على دقة المُصنّفين المطورين. في التجارب الأولية، تم توصيف كل نمط وراثي كسلسلة ثنائية ذات 23 خانة، حيث تشير كل خانة من الخانات 14 الأولى إلى ما إذا استخدم متغير دخل معين. وتوافق الخانات الثمانية التالية (مقسمة إلى أربع مجموعات من خانتين) اختيار استخدام عقدة طبقة خفية معينة، وشكل تابع التفعيل في تلك العقدة الخفية. تُرمّز الخانة الأخيرة اختيار تابع التفعيل في عقدة الخرج.

دُربت كل MLP ناتجة ثلاث مرات باستخدام خوارزمية الانتشار الخلفي بأخذ قيم عشوائية ابتدائية مختلفة لأشعة الأوزان للتقليل من مشكلة تقييم ملاءمة المشوشة، التي يمكن أن تظهر عندما تُطوّر البنية الهندسية لأي شبكة (yao, 1999). اُستخدم معدل ثلاث قيم ملاءمة لقيادة العملية التطورية. قُسمت مجموعة معطيات بناء النموذج لتعطي مجموعة معطيات تدريب ومجموعة معطيات اختبار (داخل العينة). بُنيت الشبكات باستخدام معطيات التدريب، وتم الوصول إلى ملاءمة الشبكة أثناء العملية التطورية اعتماداً على أدائها مع مجموعة معطيات الاختبار، حيث اُعتبرت الشبكات ذات دقة التصنيف الأعلى هي الأكثر ملاءمة. لم تُستخدم المجموعة خارج العينة في عملية تطوير النموذج.

كانت العملية التطورية خلال كل توليد كالآتي: طُبقت عملية اختيار وليت، والتي تفضل بوضوح الأعضاء الأكثر ملاءمةً من المجتمع الحالي – لاختيار أعضاء من أجل بركة التزاوج. اُختيرت الآباء بشكل عشوائي من هذه البركة، وطُبق تصالب أحادي النقطة باحتمالية مقدارها 0.5 لإنتاج أنماط وراثية الابن. ثم طُبق معامل الطفرة، الذي بموجبه يمكن أن تُبدل كل خانة من نمط وراثي ابن باحتمالية مقدارها 0.4 بغية إنتاج طفرة واحدة متوقعة تقريباً لكل نمط وراثي ابن. أخيراً، اُستبدل المجتمع الحالي من الأنماط الوراثية بالأنماط الوراثية الابن. كان اختيار القيم البارامترية من أجل GA حُكمياً، ووَجّه بالتجارب الأولية من قبل العالم Mitchell (1996)، الذي يقترح بأنه بشكل شائع تُستخدم في تطبيقات عملية GA أحجام مجتمع بحوالي 50 معدل تصالب بقيمة 0.6، ومعدل طفرة خانة مقدارها 0.01. يحدد قسم العمل المستقبلي لهذا الفصل استراتيجيات اختيار واستبدال، وتوليد تنوع بديلة يمكن أن تُدرس في امتدادات مستقبلية لهذه الدراسة.

النتائج والمناقشة

يبين (الجدولان 4 و5) مصفوفات تشوش داخل العينة وخارج العينة من أجل صك متوقع مقابل الفعلي لحالة التصنيف الثاني مُقسمة على نحو متساوٍ عبر سبع تقطيعات لمجموعة المعطيات. وتم الحصول على دقة تصنيف داخل (خارج) العينة مقدارها 83.08% (81.43%). ولوُحظ بأن الدقة متماثلة إلى حد معقول بين صفي التخمين. يبين (الجدول 6) مصفوفة تشويش لخارج العينة من أجل تخمين الصكوك المتوقع مقابل الفعلي من أجل مسألة التصنيف رباعية التخمين. وكما كان متوقعاً، فإن حالة الصفوف الأربعة هي اختبار أكثر تطلباً لنموذج التصنيف، وهبطت الدقة العامة للتصنيف داخل العينة (خارج العينة) المكتسبة إلى 48.75% (49.29%). لفحص دقة التصنيف بإحكام أكثر، تم أيضاً حساب دقة تصنيف ذات "خطوة واحد بعيداً"، التي تقيم كم من التخمينات المتوقعة هي ضمن درجة واحدة من التخمين الفعلي. في هذه الحالة، تم الحصول على دقة تصنيف مقدارها 92.5% (92.1%) مشيرةً إلى حدوث بضعة تصنيفات تخمين خاطئة كبيرة نسبياً.

بغية تقييم دقة التصنيف خارج العينة حُسبت إحصائية Q لوكالة Press لكلٍّ من نموذج التصنيف الثنائي، ونموذج التصنيف رباعي التخمين. في كلا الحالتين، فإن فرضية العدم – بأن دقة التصنيف خارج العينة ليست أفضل بشكل ملحوظ من تلك التي قد تحدث بالصدفة لوحدها – قد رُفضت عند المستوى 1%.

الجدول (4) دقة تصنيف ثنائي داخل عينة لأفضل MLP مطورة مأخوذة كمتوسط لسبع تقطيعات معادة.

	متوقع		
فعلي	درجة استثمار	درجة غير استثمارية	المجموع
درجة استثمار	(79.11%) 126.6	(20.89%)33.4	(100%) 160
درجة غير استثمارية	(12.95%)20.7	(87.05%) 139.3	(100%) 160
المجموع	147.3	172.7	(100%) 320

الجدول (5) دقة تصنيف ثنائي خارج عينة لأفضل MLP مطورة مأخوذة كمتوسط لسبع تقطيعات معادة

	متوقع		
فعلي	درجة استثمار	درجة غير استثمارية	المجموع
درجة استثمار	(85.71%)60	(14.29%)10	(100%)70
درجة غير استثمارية	(22.86%)16	(77.14%)54	(100%) 70
المجموع	76	64	(100%) 140

الجدول (6) دقة خارج العينة من أجل حالة تصنيف رباعية (أفضل MLP مطورة) مأخوذة كمتوسط لسبع تقطيعات معادة.

	متوقع				
فعلي	A	BBB	BB	B	المجموع
A	12 (34.29%)	17 (48.57%)	4 (11.43%)	2 (5.71%)	35 (100%)
BBB	5 (14.29%)	24 (68.57%)	6 (17.14%)	0 (0.0%)	35 (100%)
BB	1 (2.86%)	10 (28.57%)	14 (40.0%)	10 (28.57%)	35 (100%)
B	1 (2.86%)	3 (8.57%)	12 (34.29%)	19 (54.29%)	35 (100%)
المجموع	19	54	36	31	140

يبين (الجدول 7) تفاصيل النسب المستخدمة من قبل MLP المطورة الأفضل لحالة التصنيف الثنائية. المتغيرات المفتاحية هي حجم الشركة، وربحيتها، وتاريخ ربحها منذ تأسيسها ومدى تغطيتها للفائدة، والتغيير في ممتلكاتها الكلية في السنوات الثلاث الماضية (وكالة من أجل تاريخ ربحها الحالي). كلٌّ من هذه النسب هي متغيرات معقولة في تقييم قابلية النجاح المستقبلية للشركة . وتمت ملاحظة أن غالبية MLPs في المجتمع استعملت مدخلات متشابهة عند نهاية 80 تكرار تطوري. أظهر فحص البنية الداخلية الأفضل MLP بأنها استعملت أربعة عقد طبقة خفية بتوابع تفعيل منطقية عند كل عقدة طبقة خفية. يبين (الجدول 8) أيضاً تفاصيل النسب المستعملة من قبل نموذج MLP الأفضل المطور من أجل حالة التصنيف رباعية التخمين. النسب المختارة مماثلة لتلك من أجل حالة التصنيف الثنائي: حجم الشركة، وربحيتها. ومقياس سيولتها لأجل قصير، والتغيير في ممتلكاتها الكلية خلال السنوات الثلاث الماضية.

الجدول (7) المدخلات المستخدمة في نموذج MLP الأفضل من أجل التصنيف الثنائي ومن أجل حالات التخمين الأربعة.

تصنيف ثنائي	تصنيف رباعي التخمين
السجل (الممتلكات الكلية)	السجل (الممتلكات الكلية)
الدخل الصافي/المبيعات	النسبة الجارية
EBIT/الفائدة	النسبة المئوية للتغيير في الممتلكات الكلية
النسبة المئوية للتغيير في الممتلكات الكلية	الدخل الصافي/الممتلكات الكلية
الدخل الصافي/الممتلكات الكلية	
الأرباح غير الموزعة/الممتلكات الكلية	
الجرد/رأس مال المعامل	

الجدول (8) معدل ملاءمة المجتمع (داخل العينة) لأفضل 10، MLP لأول تنفيذ عشوائي لمجموعة المعطيات.

توليد	متوسط (%)	الانحراف المعياري
10	84.05	0.68
20	84.75	0.50
30	85.04	0.44
40	85.29	0.35
50	85.31	0.34
60	85.39	0.36
70	85.46	0.33
80	85.52	0.33

أظهر فحص البنية الداخلية لأفضل MLP مطورة بأنها استعملت ثلاثة عقد طبقة خفية (تابعي تفعيل منطقي وتابع تفعيل خطي).

خلال اختيار عدد التوليدات (80)، وُجّهنا بنتائج التجارب التمهيدية، التي اقترحت بأن معدل الملاءمة (دقة التصنيف على معطيات التدريب) في المجتمع قد تقاربت نموذجياً إلى مرحلة استقرار خلال حوالي 50 توليد. لتوضيح تقارب دقة التصنيف، تم جدولة معدل ملاءمة المجتمع، الأفضل 10 MLPs في المجتمع كل 10 توليدات من أجل أول تنفي عشوائي لمجموعة المعطيات في الجدول (10). إن تقارب معدل الملائمة داخل العينة في المجتمع ملحوظ بالتوليد 50.

أثناء تطوير بنيات MLPs المذكورة سابقاً، حُدّد عدد العقد الخفية ومدخلات النسب، التي يمكن أن تكون متضمنة إلى أربعة وثمانية على الترتيب. وتم القيام بذلك بغية المحافظة على درجات الحرية في النماذج النهائية بحيث تقلل فرص الإفراط في الملائمة.

التساؤل الطبيعي هو فيما إذا كان لهذه القيود تأثير عكسي على دقة التصنيف المكتسبة. بغية فحص هذه القضية، أُجريت سلسلة من التجارب الإضافية باستخدام مجموعة معطيات التصنيف الثنائي (درجة استثمار مقابل درجة غير استثمارية). وفي التجربة الأولى، تمت زيادة المدخلات المباحة إلى 12. وقُيّدت عدد المدخلات في التجربة الثانية إلى ثمانية، ولكن سُمح للبنية الداخلية لـــ MLP باحتواء بحدود طبقتين خفيفتين، وكل طبقة خفية يمكن أن تحتوي حتى ثمانية عقد.

وقد وجد بأن دقة التصنيف داخل العينة وخارج العينة لا تتغير لدرجة كبيرة في كل من التجربتين عن تلك المنشورة.

نموذجياً، استمرت MLP المطورة باستخدام حد أعلى من سبع مدخلات وطبقة خفية واحدة. وهكذا، لم يوجد هناك دليل على أن القيود على عدد المدخلات أو عدد عقد الطبقات الخفية تؤثر عكسياً على النتائج المنشورة.

استنتاجات

بحث هذا الفصل استخدام هجين من MLP/GA يدمج إمكانية البحث العام لخوارزمية تطورية مع قدرات نمذجة غير خطية لـ MLP أثناء نمذجة عملية تخمين مُصدّر صكوك متعلق بالشركات. وقد بُنيت سلسلة من نماذج التصنيف. على الرغم من استخدامها كدخل معطيات مالية سُحبت من شركات في تشكيلة من القطاعات الصناعية، أوضحت النماذج مقدرة مفيدة للتمييز بين تصنيفات تخمين صكوك النتائج المكتسبة، التي كانت أفضل بشكل ملحوظ من الاحتمال العشوائي. كما أوضح الفصل أيضاً إمكانية تطبيق الخوارزميات التطورية لأتمتة عملية الاستهلاك الزمني لخلق MLPs.

العمل المستقبلي

يبين هذا الفصل مثالاً على كيف يمكن لعناصر مهمة بناء MLP أن تؤتمت بواسطة خوارزمية وراثية. تُركت تشكيلة من السُبل لاختبارات أخرى. فيما يتعلق بالـ GA، يوجد تشكيلة من الاستراتيجيات اختيار بديل، واستبدال، وتوليد متنوع الأشكال، يمكن أن تُستخدم وتُحسن النتائج أكثر . على سبيل المثال، يمكن أن يؤدي استخدام اختيار الروليت إلى فقدان التنوع في مجتمع الأنماط الوراثية مؤديةً إلى تقارب مجتمع بنى MLP الناتجة. وسيكون امتداد مثير للدراسة دراسة فيما إذا سيُحسن استخدام طريقة اختيار مع ضغط اختيار أقل النوعية لـ MLPs المُطورة بالحفاظ على مجتمع أنماط وراثية متنوع أكثر. تتضمن طرق الحفاظ على التنوع تطبيق معامل الزمرة (Mitchell, 1996)، الذي بموجبه يستبدل نمط وراثي مُشكّل حديثاً النمط الوراثي الأكثر تشابهاً لنفسه في المجتمع الموجود، أو بتطبيق اشتراك الملاءمة (Goldberg & Richardson, 1987)، حيث تُخفض الملاءمة لأنماط وراثية إذا كان هناك أنماط وراثية أخرى مماثلة في المجتمع. يمكن أن تؤدي الطريقة الأخيرة إلى مضاربة في مجتمع الأنماط الوراثية تؤدي إلى تسلق القمم المتميزة على منظر الملاءمة، إن كانت موجودة. إذا كان لهذه القمم ملاءمة متماثلة، فإن ذلك سيقترح وجود مجال من بنيات MLP، التي ستعطي نتائج متكافئة. أما استراتيجيات الاستبدال البديلة التي يمكن أن تُطبق على المسالة، فتتضمن حالة مستقرة، حيث يتم استبدال فقط بعضة سلاسل فردية –

تكون الأقل ملائمة عادةً – بأنماط وراثية جديدة خلال كل توليد. يمكن أيضاً أن تُستكشف أشكال بديلة وأصناف من التصالب – مثل التصالب أحادي النقطة أو التصالب المُوحد – لتحديد فيما إذا بالإمكان تحسين دقة التصنيف بشكل أكبر. وبشكل عام أكثر، فلقد لوُحظ بأنه يوجد مجال كبير من التطبيقات لـ MLPs في مجال المالية تتضمن توقع السوق، وإحراز الائتمان، والتنبؤ بالمبيعات/الأرباح، وكشف الاحتيال، وأَمْثلة حقيبة الأوراق التجارية (Wong, Lai & Lam, 2000). تقدم هذه المسائل إمكانية لتطبيق منهجية GA/MLP مدمجة.

المراجع

Altman,E. (1993). Corporate financial distress and bankruptcy. New York: John Wiley and Sons.

Back, B., Laitinen, T., Sere, K.,& van Wezel,M.(1996). Choosing bankruptcy predictors using discriminant analysis, logit analysis and genetic algorithms. Technical Report no. 40. Turku Centre for Computer Science, Turku School of Economics and Business Administration.

Baker, B.M., & Ayechew, M.A. (2003). A genetic algorithm for the vehicle routing problem. Computers & Operations Research, 30(5), 787-800.

Bauer, R. (1994). Genetic algorithms and investment strategies. New York: John Wiley & Sons.

Bond Market Statistics (2003). New York: The Bond Market Association.

Brabazon, A. (2002). Neural network design using an evolutionary algorithm. Irish Accounting Review, 9(1), 1-18.

Brabazon, A., & Keenan, P. (2004). A hybrid genetic model for the prediction of corporate failure. Computational Management Science, I (3-4), 293-310.

Brabazon, A., & O'Neill, M. (2003). Anticipating bankruptcy reorganisation from raw financial data using grammatical evolution. In G. Raidi, J.A. Meyer, M. Middendorf, S. Cagnoni, J.J.R. Cardalda, D.W. Corne, et al. (Eds.), Proceedings of EvolASP 2003, Lecture Notes in Computer Science (2611): Applications of Evolutionary Computing (pp. 368-378). Berlin: Springer-Verlag.

Brennan, D., & Brabazon, A. (2004, June 2004). Corporate bond rating using neural networks. In H. Arabnia et al. (Eds.), Proceedings of the International Conference on Artificial Intelligence 2004 (ICAI '04), Las Vegas, NV (vol. 1, pp. 161-167). CSEA Press.

Business Week (2003, August 4). A frenzied race to refinance. Business Week, p. 38.

Deboeck, G. (1994). Trading on the edge: Neural, genetic, and fuzzy systems for chaotic financial markets. New York: John Wiley & Sons.

Dorado, J., Santos, A., & Rabuñal, J. (2001, June 13-15). Connectionist models of neurons, learning processes and artificial intelligence. In Proceedings of the 6th international Work-Conference on Artificial and Natural Neural Networks, IWANN 2001 .Lecture Notes in Computer Science (2084), Granada, Spain (vol. 1, pp. 717-724). Berlin: Springer-Verlag.

Dutta, S., & Shekhar, S. (1988). Bond rating: A non-conservative application of neural networks. Proceedings of IEEE International Conference on Neural Networks (vol. 2, pp. 443-450).

Ederington, H. (1985). Classification models and bond ratings. Financial Review, 20(4), 237-262.

Gentry, J., Whitford, D., & Newbold, P. (1988). Predicting industrial bond ratings with a probit model and funds flow components. Financial Review, 23(3), 269-286.

Goldberg, D. (1989). Genetic algorithms in search, optimisation and machine learning. Boston: Addison Wesley Longman.

Goldberg, D.,& Richardson, J.(1987). Genetic algorithms with sharing for multi-modal function optimization. In J. Grefenstette (Ed.), Genetic algorithms and their applications. Proceedings of the Second International Conference on Genetic Algorithms. Erlbaum.

Hair, J., Anderson, R., Tatham, R., & Black, W. (1998). Multivariate data analysis. Upper Saddle River, NJ: Prentice Hall.

Holland, J. (1975). Adaptation in natural and artificial systems. Ann Arbor: University of Michigan Press.

Horrigan, J. (1966). The determination of long term credit standing with financial ratios, Journal of Accounting Research, (supplement), 44-62.

Huang, Z., Chen, H., Hsu, C., Chen, W., & Wu, S. (2004). Credit rating analysis with support vector machines and neural networks: A market comparative study. Decision Support Systems, 37(4), 543-558.

Kumar, N., Krovi, R., & Rajagopalan, B. (1997). Financial decision support with hybrid genetic and neural based modelling tools. European Journal of Operational Research, 103(2), 339-349.

Maher, J., & Sen, T. (1997). Predicting bond ratings using neural networks: A comparison with logistic regression. Intelligent Systems in Accounting, Finance and Management, 6, 23-40.

Mitchell, M. (1996). An introduction to genetic algorithms. Cambridge, MA: MIT Press.

Moody, J., & Utans, J. (1995). Architecture selection strategies for neural networks application to corporate bond rating. In A. Refenes (Ed.), Neural networks in the capital markets (pp. 277-300). Chichester, UK: Wiley.

Pinches, G., & Mingo, K. (1973). A multivariate analysis of industrial bond ratings. Journal of Finance, 28(1), 1-18.

Pogue, T., & Soldofsky, R. (1969). What's in a bond rating? The Journal of Financial and Quantative Analysis, 4(2), 201-228.

Sarker, R., & Newton, C. (2002). A genetic algorithm for solving economic lot size scheduling problem. Computers & Industrial Engineering, 42(2-4), 189-198.

Shin, K., & Han, I. (2001). A case-based approach using inductive indexing for corporate bond rating. Decision Support Systems, 32, 41-52

Sipper,M., & Sanchez,E. (1997). A phylogenetic, ontogenetic, and epigenetic view of bio-inspired hardware systems. IEEE Transactions on Evolutionary Computation, 1(1)83-97.

Surkan, A., & Singleton, J. (1990). Neural networks for bond ratings improved by multiple hidden layers. In Proceedings of the IEEE international Conference on Neural Networks, San Diego, CA (vol. 2, pp. 163-168).

Varetto, F. (1998). Genetic algorithms in the analysis of insolvency risk. Journal of Banking and Finance. 22 (10), 1421 -1439.

West, R. (1970). An alternative approach to predicting corporate bond ratings. Journal of Accounting Research, 7, 118-127.

Wong, B., Lai, V.,& Lam,J. (2000). A bibliography of neural network business applications research: 1994-1998. Computers and Operations Research, 27(11-12), 1045-1076.

Yao, X. (1999). Evolving artificial neural networks. Proceedings of the IEEE. 57(9), 1423-1447.

Yesilyaprak, A. (2004). Bond ratings with artificial neural networks and econometric models. American Business Review, 22 (1), 113-123.

القسم 6
تطبيقات أخرى

الفصل الثاني عشر

الموسيقى والشبكات العصبونية

ملخص

يتعلق هذا الفصل بالبحث في مجال الموسيقى والشبكات العصبونية الصنعية، تُؤخذ بالحسبان المحاولات الأولى لتصنيف الإدراك الموسيقي البشري بواسطة الشبكات العصبونية الصنعية بالإضافة إلى التقنيات الأخيرة والأكثر تعقيداً، التي تسمح للحاسبات بتعلم، وتمييز الأساليب الموسيقية، أو الأنواع، أو حتى لتأليف الموسيقى. تتعلق المواضيع الخاصة المغطاة بتمثيل اللغة الموسيقية، وبالأنظمة المختلفة المستخدمة من أجل حلها، ابتداءً من شبكات الانتشار الخلفي الكلاسيكية، وحتى خرائط التنظيم الذاتي، والشبكات المعيارية. نأمل بأن هذا الفصل سيكشف بعض المعلومات الهامة حول ظهور حقل فرعي حام من الذكاء الصنعي (AI)، وبنفس الوقت يزيد بعض الاهتمام، ويسمح بفهم أفضل لهذا المجال المعقد.

مقدمة

قبل حوالي 20 سنة علّق العالمان James McClelland وDavid Rumelhart (1986) على التناقض الواضح: فبالرغم من حقيقة أن هناك آلات قوية حسابياً أكثر فأكثر متوفرة للباحثين، فما زالت القدرة الإنسانية على تنفيذ مهام معينة لا تضاهى.

إضافة لذلك، بالعلاقة مع بعض السمات - كتمييز الأشكال مثلاً - فإن ما استطاعت أن تفعله الآلات (ولو أنها مُحسنّة بالاستناد إلى التصميم بحجم صغير والقوة الحسابية) كان ضئيلاً جداً.

ولكن ما الذي يجعل البشر أذكى من الآلات؟ إنهم بالتأكيد ليسو أسرع أو أكثر دقةً. رغم ذلك، فالبشر أفضل بكثير في إدراك الأجسام في المناظر الطبيعية وملاحظة علاقاتها، وفي فهم اللغة واسترجاع معلومات ملائمة بشكل سياقي من الذاكرة، وفي وضع الخطط وتنفيذ أعمال ملاءمة سياقياً، وفي مجال واسع من مهام الإدراك الطبيعية الأخرى. كما أن البشر أيضاً أفضل بكثير في تعلم فعل تلك الأشياء بدقة أكثر وبطلاقة من خلال خبرة المعالجة. ما هو الأساس

لتلك الاختلافات؟. ومن وجهة نظرنا، فإن البشر أذكى من حاسبات اليوم، لأن الدماغ يستعمل بنية هندسية حسابية أساسية، مناسبة أكثر للتعامل مع سمة مركزية لمهام معالجة المعلومات الطبيعية، التي هم ممتازون فيها. سوف نبين من خلال أمثلة، بأن تلك المهام تتطلب عموماً اعتبارات متزامنة لعديد من المعلومات أو القيود (Rumelhart & McClelland 1984, P.3). ميّز الباحثان McClelland وRumelhart البنية الهندسية الحسابية الأساسية للدماغ (بلايين من الوحدات المتصلة مع بعضها البعض، وهي العصبونات)، بالإضافة إلى قدرته على تأمل قيود وفيرة بشكل آني و"شظايا" المعرفة، وهو أحد أسباب الكمال المطلق لقدرات الإنسان في إدارة المعلومات. سيكون درسهم قادراً على حث عدد فوق العائدة من التقدمات في تطوير الأنظمة الذكية، وأيضاً سوف يُعيد قسم كبير من الجمهور العلمي قراءة الإدراك من المنظورات الإبداعية، لدرجة أنه يمكن أن يتم تبني القول "ثورة الاتصالية" من قبل بعض العلماء (Medler, 1998).

سنأخذ في هذا الفصل بالاعتبار بعض السمات الأساسية لموضوع الموسيقى وANNs بتقديم كلٍّ من المواضيع المنهجية والمنشأية لهذا المجال الجديد من المعرفة (الموسيقى والذكاء الصنعي، وبناءً على ذلك الموسيقى وANNs). بعد ذلك سنقدم مراجعة واسعة للمادة المنشورة حول هذا الموضوع مُقسمةً إلى المادة المنشورة للسنوات الأولى، والمادة المنشورة الحالية. تأتي الحاجة للتمييز بين المادة المنشورة القديمة والجديدة من منظور مختلف موصوف، مُوجّه "بمستوى منخفض" أكثر في السنوات الأولى (كما هو متوقع، بما أن القضايا التمثيلية – كيف تُرمّز الدرجات والممدد ...الخ – كانت محاولة للبدء بها). ونركز أكثر على خلق نماذج واسعة من الإدراك الموسيقي في السنوات الحالية (في المحاولة الرائعة لنمذجة المواضيع عالية المستوى مثل، تمييز الأنواع والأساليب الموسيقية ...الخ). تطرح أي مناقشة على ANNs والموسيقى أيضاً سؤالين أساسيين للدراسة. تعتبر هذه الأسئلة فوق الحدود المُمثلة بالسمات الحسابية للنموذج. في الحقيقة، تبدو أنها مرتبطة بشكل وثيق من جهة بإمكانية استخدام الاتصالية لاتصال بمفاصل للنماذج الواقعية من الإدراك الموسيقي في العموم (وهكذا بإنجاز فهم أفضل لتلك السمات من الإدراك التي تبدو طبيعية جداً للبشر). ومن جهة أخرى، للبحث عن حل المسائل غير القابلة للمحاكاة (أو على الأقل قابلة للمحاكاة بصعوبة) بواسطة تقنيات الذكاء الصنعي التقليدية (AI): إنه مطلوب جداً – وفي الحقيقة – تجسيد المحفزات ذات المعنى متعددة الأبعاد والمعقدة، وتطوير النماذج الفعّالة (على سبيل المثال، من أجل تمييز الوجوه أو تمييز الأساليب الموسيقية). يجب أن تُدرس النقطة الأخيرة بأهمية خاصة بالاتصال مع مواضيع هذا الفصل. بما أن الشبكات العصبونية (بالإضافة إلى الدرجة) أفضل من "الواقعية البيولوجية"، فهي تُقدم من أجلِ نمذجة الإدراك الموسيقي، انظر Buzzana، 2002a)، وسمحت لحل المسائل أن يُعتبر منيعاً حقاً بطرق الذكاء الصنعي التقليدية، كما في حالة الدراسات على الأداء الموسيقي الآلي (راجع Bresin ,2000).

الموسيقى والذكاء الصنعي (AI)

يجب على أي فصل مُكرّس للشبكات العصبونية الصنعية وبحث الموسيقى أن يأخذ بالحسبان، أن القارئ قد يأتي من حقول مختلفة جداً من الخبرة: الموسيقى، علم الحاسوب، علم الإدراك ... وهلم جراً. ولذلك، يبدو مرغوباً التذكير ببضعة أفكار عامة تتعلق بهذا الحقل الجديد، حيث يجتمع علم الحاسوب والموسيقى. وبالتالي، يفترض أن يكون القارئ على إلمام بالأفكار الرئيسية في الشبكات العصبونية ونظرية الموسيقى.

الموسيقى وAI (والمُسمى أيضاً بعلم الموسيقى الإدراكي أو علم الموسيقى الحسابي) هو حقل فرعي منبثق من AI، الذي يستغل تنوع المجالات، ويهدف إلى فهم أفضل لكيفية عمل الموسيقى (راجع Reck Miranda ,2000، على سبيل المثال). ينتج هذا الحقل المعقد والغني جداً من تركيب عدة مجالات مختلفة من المعرفة والموسيقى وعلم الحاسوب وعلم الإدراك وأيضاً الرياضيات، والفيزياء وعلم اللغة ... وهلّم جراً. وهذا يعني بوضوح، أنه حتى بالرغم من أن العديد من الفروع الموجهة تتعايش ضمن نفس المجال (الموسيقى المُوجّهة. والهندسة الموجّهة، والإدراك المُوجه ...الخ)، وتعمق معرفة جديدة بشكل مستمر للدوافع والأهداف والطرق، فهناك نموذجان أساسيان يميزان كامل البحث الموجود: طريقة AI التقليدية والاتصالية (والمشار إليها أيضاً بالمعالجة الموزعة المتوازية)، والشبكات العصبونية الصنعية ... الخ).

أنه من المعلوم جيداً، بأن طريقة AI التقليدية (Newel & Simon, 1972) تهدف إلى محاكاة سلوك ذكي، بمثل المعلومات من خلال رموز كما في الأنظمة الحاسوبية (وتدعى أيضاً أنظمة خبيرة)، التي تُرمّز المعرفة على شكل قواعد، تُستعمل فيما بعد لحل مسائل معينة. يكون هذا النموذج مناسباً بشكل خاص لتلك الحالات، حيث من الممكن وصف مسألة ما في شروط إجرائية (بمعنى آخر، لتلك الحالات التي تجعلنا نؤسس العمل الأفضل للمباشرة عند مواجهة شرط معين: <فعل then <حالة> if). الحقيقة، أنه في هذه الأنظمة كل قاعدة تمثل "شظايا" من المعرفة منفصلة بشكل واضح عن بعضها البعض، وتجعلها سهلةً نسبياً لإدارة تعقيد المنظومة بالكامل على الرغم من ذلك. فالحقيقة، أن هذه الطريقة تعتمد كلياً على المعرفة الواضحة، وتشكل أحياناً نقصاً جدياً، بما أن الكثير من العمليات لا تبدو قابلة للتقييد ضمن الحدود الصارمة الناتجة بالتقسيم إلى أجزاء غير مرتبطة و/أو مضادة (أي القواعد). ويبدو ذلك حقيقياً بشكل خاص عند التعامل مع سمات معينة من الإدراك الموسيقي: في الحقيقة، بينما هو من المعقول والعملي تصنيف وتر باستخدام القواعد (مثال على ذلك، إذا أظهرت النغمات الثلاثة لوتر مجالاً ثالثاً رئيسياً بين الأول والثاني، وخامساً مضبوطاً بين الأول والثالث، عندئذ يكون لدينا وتر رئيسي)، فإنه من شبه المستحيل فعل ذلك لشيء متقلب مثل الأسلوب الموسيقي. حتى بالرغم من أنه حقيقي، أننا

قد نحاول اكتساب الأسلوب الموسيقي من خلال القواعد (على سبيل المثال، القواعد التي تصف بعض قواعد اللغة كما في (Baroni, Dalamonte & Jacoboni, 1999)، فمن الحقيقي أيضاً أننا سننهي بكل تأكيد بناء قاعدة لغوية ما بشكل غير عملي، بحيث – وبعيداً عن تعقيدها الداخلي – ستتوقف عن خدمة وظائف التعميم، التي هي التعريف وغرض القواعد في المقام الأول (Buzzanca, 2002a).

إضافة إلى ذلك، من الصعب جداً، إن لم يكن مستحيلاً، بناء قاعدة لغوية قادرة على تضمين كافة الحالات الحقيقية لأسلوب ما واستثناء كافة الحالات الخاطئة. كنتيجة لذلك، فإن قسماً صغيراً فقط من الأمثلة المُنتجة بتلك القاعدة اللغوية سيعبر عن حالات فعلية من الأسلوب، الذي يكون مفترضاً للنمذجة. وبشكل عام أكثر ، يمكننا أن نؤكد إيجابياً – في منظور إدراكي – أننا نستعمل القواعد عند التمييز بين الأساليب الموسيقية. وفقط لمجاراة هذا المثال، كل شخص يعلم بأن تمييز الأسلوب الموسيقي هو بطريقة ما جوهري لطبيعة البشر، وبالتالي حتى الشخص البسيط المتوسط يمكن أن يختبر الفرق بين ترتيل من قبل Josquin وسمفونية من قبل Beethoven، حتى بالرغم من أنه لم يسبق له أن حصل على أي تعليم موسيقي. يقترح هذا بوضوح، أنه يمكن للموسيقى أن تُعرّض الباحث إلى الكثير من المعلومات بشكلٍ ما، بحيث تجعل من الصعب (أو حتى من المستحيل) إسهاب الأوصاف الرمزية وخاصةً في منظورٍ مخيلة الحقيقة الإدراكية. لذلك، فإن الحاجة لتقليد سمات معينة من الإدراك الموسيقي (السمات التي لا يمكن للقواعد أن تكشفها بفعالية) لتكون مأخوذة بالاعتبار هي أحد الأسباب التي حُددّت خلال السنوات الحالية نحو الاهتمام بالطريقة الاتصالية، سويةً مع حقيقة أن العمليات الإدراكية العديدة قد بُرهنت (بالمماثلة من وجهة نظر تمييز الأسلوب الموسيقي، أو القدرة على عزف الموسيقي) خارج وعينا المُدرك (Velmans, 1991). من المعلوم جيداً في الشبكات العصبونية الصنعية (McClelland & Rumelhart, 1986) – أن يكون هناك إحساس واسع جداً – يحاكي البنية ووظيفة الدماغ لتقديم أسلوب جديد كلياً لمعالجة المسائل بواسطة عدد هائل من المعالجات الأولية المتصلة بينياً (أي، مُركبات الشبكات، العصبونات) التي تعمل في طريقة موزعة متوازية. تسمح هذه الطريقة للتعلم وإمكانيات التعميم، والتي سويةً مع تحمل التشويش تشكل سمات هامةً من أجل نمذجة الإدراك الموسيقي. في الحقيقة، كمية كبيرة من النشاطات الموسيقية التي نعمل فيها، تقابل الضرورة لاستخراج معرفة ضمنية من الأمثلة: كالمسائل، التي تظهر أثناء عملية الوصول إلى المعرفة (التعلم، تحقيق القيود، تجريد الميزات، تعميم الذكاء)، هي بطريقة ما مُجسّدة في الطريقة الاتصالية. يطبق نفس الأمر على المهام الموسيقية، التي تتطلب معالجة فعالة منخفضة المستوى للمعطيات المشوشة (فهم الدرجة، طابع الصوت، ... الخ)، والتي يكون من المستحيل التعامل معها بواسطة طرق AI التقليدية.

إن حقيقة، أن ANNs لا تتطلب معلومات تُبنى في أي دور موجود سابقاً، قد سمحت للباحثين (كما سنشرح حالاً) بمعالجة عدد من الأسئلة التي تخص الإدراك الموسيقي، والتي أُثبت بأنها مستحيلة الحل في نمط رمزي (Buzzanca, 2002). بالرغم من ذلك، فإن ذلك يجب أن لا يخدع القارئ للتفكير، بأن نمذجة الموسيقى عبر شبكات عصبونية هي مهمة عادية: إن العديد من الأسئلة فيما يتعلق بترميز المعطيات في كلٍ من المستوي الصفري (نغم، إيقاع، المخطط المنحني ... الخ) وفي المستوى الكبير (اتجاهية الموسيقى، مستويات التدرج ... الخ) سويةً مع بارامترات حاسمة أخرى، تشكل جهداً أثناء المناقشة حولها عندما تحدث.

الموسيقى وANNs

إن القضايا المُناقشة في هذا الفصل لا تزعم بأنها مناقشة شاملة لكافة الأسئلة ذات الصلة المتضمنة في مجال الموسيقى والشبكات العصبونية. وهذا أيضاً المجال، الذي هو حالياً أحد حقول الدراسة المتبادلة جداً، فقد ساهمت الرياضيات، بالإضافة إلى علم الإدراك، في تحسين هذا المجال، وهذا يعني في النهاية بأنه يمكن أن تُعّلم الدروس الهامة في مجالات أخرى: العديد من المصادر الثمينة قد افتقدت بلا شك. بالرغم من ذلك، فإننا نعتقد بأنه يمكن أن يكون هذا الفصل نقطة بداية جديدة لبحث المجال بتأكيد المنشورات الحالية، فهي تتضمن تقارير التجارب والمناقشات النظرية وتواريخ الحالة، والتقنيات الجديدة ... وهكذا.

وكما قيل سابقاً، فإن مجال الموسيقى وANNs يجمعان مساهمات عدد من المجالات المختلفة في محاولة لتحقيق فهم أفضل للعمليات المتضمنة في إنتاج الموسيقى وإدراكه وتقديره.

كما سيُلاحظ القارئ في كافة الفقرات القادمة. يُميز اتجاهان مختلفان المادة المنشورة المُناقشة هنا. يدّعي أحدهما بأن الشبكات العصبونية تسمح بنمذجة دقيقة للإدراك الموسيقي البشري والسلوك (على سبيل المثال Large, Palmer, & Pollack, 1999، Krumhansl et at., 2000، Buzzanca, Buzzanca, Gargiulo, & Lamanna, 2003)، والأخير الذي يمكن أن يُعتبر أقرب إلى مجال تعلم الآلة المهتم أكثر في ANNs كالتقنيات، التي تسمح للحاسبات أن تتعلم، وضمن شروط معقولة تمتنع عن الحاجة للتدخل البشري في تحليل المعطيات (وهذه هي بالتحديد حالة تلك الدراسات على التمييز الآلي للأسلوب الموسيقي، مثل Rauber & Frühwirth, 2001 على سبيل المثال).

بيّن الباحث Buzzanca (2001) كيف يمكن أن يكون تحليل الأسلوب الموسيقي معقداً بواسطة طريقة رمزية. تمت في عمله محاولة تمييز الأسلوب الموسيقي بواسطة نظام خبير، ينفذ قوانين

القواعد اللغوية المعينة للأسلوب كقاعدة المعرفة وتقنيات الإعراب (Baroni et al. 1999). تقترح الحاجة للقواعد (Camilleri, 1992)، وعلاوة على ذلك تعقيد تقنيات الأعراب التقليدية، طريقة مختلفة: تبدو ANNs مناسبة جداً لحلٍ مثل هذه المسائل. لا تنظم ANNs المعرفة بموجب أي أسبقية منهجية. كما هو مذكور سابقاً، فهي في الحقيقة مشكلة بعدد غزير من وحدات المعالجة المتصلة بينياً بشدة والبسيطة جداً، تجمّع كل وحدة الإشارات الواردة (من وحدات أخرى) بغية إنتاج إشارتها الخاصة (المُوجّهة إلى وحدات أخرى). سمحت هذه الطريقة (المتوازية والموزعة بشكلٍ هائل) بحل عوائق عديدة داخلية في الطريقة الرمزية امتداداً من الاتساق الأعلى لعمليات الإدراك الحقيقية إلى مثل هذه النوعيات كالانحدار الرشيق، والتكيّفية وتحمّل التشويش ... هلم جراً (Rumelhart & McClelland, 1986). في الحقيقة، من الصعب جداً إجراء معالجة أقل من تامة في النمط الرمزي.

على الرغم من ذلك، فإن الخاصية الأكثر جاذبية للأنظمة الموزعة المتوازية هي قدرتها على التعلم: المُعّرضة للأمثلة التي من الضروري أن تُعلّم، باستخدام خوارزميات خاصة، تعدل قوة الاتصالات الوحيدة بين الوحدات، كأنظمة يمكن أن تتعلم تنوعاً مختلفاً من الظواهر المعقدة جداً (تمييز الصور، نسب المعنى للكلمات ... الخ). إن القدرة على التعلم من الخبرة خلال تعديل أوزان الاتصالات تجلب وبشكل واضح المنظومات الاتصالية بالقرب من الأنظمة البيولوجية، ويجب أن تُعتبر هامة للغاية من وجهة نظر نظرية، بما أنها تقدم بديلاً مقنعاً للتعلم معتمداً على بناء القواعد الواضحة. لا تنفذ ANNs أية قيود أو قواعد موجودة مسبقاً. تظهر نمذجة حقيقة ما كظاهرة خارجية - بمعنى وصف لمستوٍ أكثر تجريدياً، بينما تُخزن المعلومات الكامنة في اتصالات الوحدات في مستوي أخفض.

وهذا ليس مفارقة كبيرة لما سترى، فإن هذه الأنظمة قادرة على تعميم (أي إدارة) حالات، لم تُدرب الأنظمة عليها من قبل. من المعلوم جيداً، بأن أي شبكة عصبونية مُدربة لتمييز المحارف المكتوبة باليد ستكون قادرة على تمييز (وإن يكن ضمن حدود معقولة) محارف مكتوبة باليد لم ترها من قبل. بكلمات أخرى، الذي يجعل هذه الأنظمة مناسبة جداً للاستعمال في مجال البحث الموسيقي، هو قدرتها على إنجاز تلك المهام المطلقة التي تتطلب اعتبارات آنية لعدد هائل من المتغيرات.

المادة المنشورة الباكرة على الموسيقى وANNs

إن التطبيقات الأولى للشبكات العصبونية في بحث الموسيقى - بدور أنظمة قادرة على معالجة المعلومات المقدمة في شكل شبه رمزي - بدأت في أواخر الثمانينات متبعةً الحماس العام الذي رافق نهضة الشبكات العصبونية من قبل الباحث Rumelhart وآخرون.

كانت الفائدة من بعض تلك المقالات هي الانتباه إلى المنظور الإدراكي، الذي ساهم في إعطاء توضيح أفضل لماذا كان لزاماً أن تُعتبر الطرق الاتصالية قيّمة في مجال بحث الموسيقى.

على الرغم من ذلك، فإن عدد وصلة ووفرة التطبيق لمثل هذه المنظومة على الموسيقى يمكن أن تُرى في ارتفاع ابتداءً من منتصف التسعينات (1990s). إن البحث المبكر (بشكل خاص ذلك المهتم بالمسائل ذات المستوى المنخفض، على سبيل المثال كيفية ترميز الموسيقى في شبكة ما، Linster 1989)، على الرغم من أنه أحياناً يكون بأسلوب مبهم وغير واضح بشكل غائي، سيشكل أساساً لتطوير النظريات والتقنيات الأخرى الأكثر تعقيداً، التي تميز روح وعمق البحث المؤخر (من منتصف التسعينات (1990s) حتى هذا اليوم) متضمنةً محاولةً لإثبات صلاحية مثل تلك النظريات والتقنيات في المستوى الإدراكي (كما في Krumhansl et at, 2000).

لذلك، ومنذ الشرارة الأولى للإلهام، فقد ازدهرت طريقة غنية جداً ومترابطة باتساق خلال السنوات الأخيرة، والتي تشمل التحليل والنمذجة لظواهر موسيقية معقدة جداً (على سبيل المثال، البحث على السمات الإدراكية المرتبطة بتمييز الأسلوب الموسيقي)، التي من أجله تأتي الإثباتات الهامة من مجالات الفسيولوجية العصبونية والتصوير العصبوني. (راجع على سبيل المثال، Janata & Grafton, 2003). من المفيد طرح هذه المناقشة لفهم سمات الجدوى، والقيود، والدوافع الضمنية لاختيار طرق معينة.

توجد إشارات عامة إلى النماذج الاتصالية في الموسيقى في Bharucha and Todd (1988)، Leman (1988)، Lischka (1991)، Loy (1991). يصف Bharucha (1988) نماذج متنوعة للإدراك الموسيقي تتضمن شبكة تحقيق قيد، التي حاول بها نمذجة الانسجام (التوافقية) النغمي. يستخدم Bharucha شبكة انتشار خلفي للخطأ لتعلم مخططات موسيقية متسلسلة وسلاسل موسيقية معينة. يمكن إيجاد مراجعة جيدة للمادة المنشورة حول هذا الموضوع من الاتجاهات لتلك السنوات الأولى في Leman (1988)، الذي أظهر أيضاً كمية المعلومات الموسيقية، التي يمكن أن تُطّبق وتُعالج بواسطة شبكة عصبونية سويةً مع نصائح مختلفة تتعلق بتطبيقات الشبكات العصبونية في مجال بحث الموسيقى (Leman, 1989).

لُخصت الاتجاهات الأكثر حداثةً من قبل الباحث Lischka (1991)، سويةً مع بيان أن أنظمة POP تسمح لطريقة بديلة وموجهة أكثر بيولوجياً. أعد الباحثان Todd وLoy (1991) سويةً مقتطعات مختارة التي – من جهة – تناقش قضايا متعددة للموسيقى الحاسوبية، ومن جهة أخرى، تبين تأثير النظريات الاتصالية عليها. تمت معالجة البحث على فهم الانسجام أو تناسق الأنغام خلال تلك السنوات من قبل عدة باحثين.

خطط الباحث Leman (1990, 1991) نموذجاً لدراسة تاريخ أدوار نمو التوابع النغمية، التي تمثل في نمط موزع فهم الأوتار بموجب نظرية الفهم النغمي للعالم Terhardt (1982).

تُعتبر الأوتار في هذا البحث "كاستاتي" متروع عن الزمن، لاحقاً تبنى الباحث Leman (1991) طريقة ديناميكية بدلاً من ذلك: تُغذى سلسلة من المعطيات الموسيقية إلى الشبكة وفقاً لسلسلة زمنية. تمت تغطية هذه الطريقة من جديد من قبل نفس المؤلف في السنوات الأخيرة (Leman & Carreras, 1996) لتحليل الكتاب الأول بعنوان Well-Tempered Clavier للمؤلف J.S. Bach.

تم تطوير نماذج اتصالية لتمييز طابع الصوت من قبل De Poli، Prandoni، Tonella (1993)، وCosi، De Poli، Lauzzana (1994). استخدم الباحث De Poli et al (1993) نسخة ثلاثية البعد لشبكة Kohonen لإعادة خلق فضاء طابع الصوت الرمادي. وحقق الباحث Cosi et al (1994) نموذجاً سمعياً (بواسطة شبكة Kohonen) لتنظيم 12 أداة موسيقية صوتية تحت شروط الإشارة الواضحة أو المشوشة. والشبكة قادرة على تمييز أشكال مشوشة من الأصوات التي تسمعها.

حقق الباحثان Desain وHoning (1989) مكمماً اتصالياً، قادراً على استنتاج وزن اللحن الصحيح، حتى وإن تمت تغذيته بمدخلات موسيقية تحتوي على ألحان تتكرر مع تغيير الوزن. يدرك نموذجهما القيم الزمنية الموجودة بين بدايات النغمات الموسيقية المختلفة، بحيث أن كل زوج من القيم يُقارن بقيمة قياسية. لا تختلف عن ذلك طريقة الباحثين Large وKolen (1994) اللذان طوّرا شبكة عصبونية تحلل الأنماط الإيقاعية.

إلى جانب الإنتاج الموسيقي الأكثر دقةً (التركيب الخوارزمي)، استخدام الباحث Todd (1989) ما يدعى بالشبكة التسلسلية المطورة من قبل الباحث Jordan: تُزود شبكة عصبونية متعددة الطبقات (بانتشار خلفي للخطأ) نغمة موسيقية واحدة كل مرة. يُعطى السياق الزمني بتجميع قيم التفعيل لوحدات الدخل. ومع ذلك، تفتقر التراكيب المنتجة بهذه الشبكة للبنية العامة (في رأي المؤلف). ولهذا السبب، يقترح Todd (1991) في مقالة تالية استخدام شبكتين متصلتين بينياً. وفي نفس التوجه، يستخدم البحث المقدم من قبل الباحث Mozer (1991, 1994) شبكات عصبونية من أجل التأليف الآلي. يوجد منظور انتقادي في Page (1994) المتعلق بالطرق الاتصالية السابقة في مجال بحث الموسيقى: لن تكون هذه النماذج مقبولة للإدراك الحسي البشري. يثني الباحث في عمله طريقة جديدة بتدريب شبكة على ألحان من أغاني تُغري الطفل بالنوم. يستخدم الباحث Kaipaninen (1994) نماذج PDP لشرح الاكتساب واستخدام المعرفة الموسيقية.

المادة المنشورة الحالية على الموسيقى وANNs

تستفيد المادة المنشورة الأكثر حداثة من اتساع التجارب السابقة. فلقد أُثبت بأن الشبكات العصبونية مناسبة للمسائل، التي يصعب أن تُوصف ضمن إطارات عمل تجمّع قواعد أو خوارزميات. وبالتالي، فإن المقدرات الموضحة بالطرق الاتصالية الباكرة توسّع نمذجة الإدراك الموسيقي لتمتد من استقصاء العمليات الإدراكية المتضمنة في تعلم الموسيقى إلى أصل الانفعالات الموسيقية.

مع ذلك، فإن نمذجة الإدراك الموسيقي بواسطة الشبكات العصبونية ليست هي المنظور الوحيد في المادة المنشورة الحالية. تأتي عدة أفكار مثيرة من دراسات تستخدم الشبكات العصبونية كمنطقة واعدة في مجال تقنيات تعلم الآلة (Buzzanca, 2003، Poncede León، Pérez-Sancho, & Inesta Quereda, 2004)، وعلى الرغم من الاختلاف الواضح، فإن هذه الدراسات تشترك في هدف أساسي هو فهم وشرح كيفية عمل الموسيقى من خلال استكشاف مُعمق لتركيبها.

ANNs والتأليف الموسيقي

تمت معالجة التأليف بواسطة الشبكات العصبونية الصنعية من قبل Hörnel & Ragg (1996)، Hörnel & Degenhardt (1997)، Hòrnel (1998) المُخلّق لـــ HARMONET، الذي هو نظام قادر على تأليف ترتيلات ذات أربعة أجزاء. يُستخدم المصطلح "ترتيلة" للدلالة على الموسيقى المتعلقة بالكنيسة اللوثرية (أو بشكلٍ عام أكثر، إلى كنائس البروتستانت). إن الضرورة المعتقدة من قبل الباحث Luther منح ظهوراً أكثر حداثة (بالمقارنة مع تأليفة عصر النهضة الموسيقية الايطالية)، وجعلها أسهل للناس في الغناء، ومتابعة الموسيقى أثناء حضور القداس أو أية طقوس دينية، هي الأساس لأي منظمة رسمية جديدة مميزة بالتركيب الطباقي البسيط والانسجام. على الرغم من المهارة الفنية المنجزة من قبل باخ (بالإضافة إلى بضعة ملحنين باروكين آخرين)، تبقى الترتيلة منتظمة جداً من وجهة نظر إدراكية، وما يجعلها مناسبة للتجريب. وفقاً للباحث Hörnel، فإن تصميم شبكة قادرة على إعادة إنتاج الأسلوب الموسيقي، يجب أن يتصرف بموجب بعض الحقائق الهامة:

1. الشبكات، التي تعتمد عدداً ثابتاً من السمات، تمتلك مشاكل بتعلم الأسلوب الموسيقي.
2. الشبكات ذات الأبعاد الصغيرة، غير قادرة على التعلم ببساطة.
3. تسعى الشبكات ذات الأبعاد الكبيرة إلى التعلم "من القلب" (أي بدون إعطاء ثقة بأنه قد حدثت عملية تعميم حقيقية).

أي شبكة تعتبر عدداً ثابتاً من الخصائص غير قادرة على إدراك ما هي السمات، التي يجب أن تؤخذ بالحسبان من أجل إعادة التجربة لذلك الأسلوب. المجموعة الكاملة المدروسة من قبل الباحث Hörnel هي الترتيلية الباروكية (Bach, Pachelbel). يهتم الحل المقترح بشكل متساو بتعلم فعال وبأسئلة إدراكية. بما أن مهمة تنسيق اللحن هي مهمة معقدة جداً، فإنها تُقسم إلى مهمات فرعية، تعتني القواعد السريعة بسمات معينة، التي اعتبرت مستقلة عن الأسلوب مثل الحدود أو وجود الأخماس المتوازية. يُخضع القسم الخلاّق إلى ثلاثة شبكات عصبونية مختلفة: الشبكة الأولى لتعلم التوابع التوافقية، والشبكة الثانية للكشف بشكلٍ صحيح للنغمة الموسيقية الجهيرة (منخفضة الحدة)، والشبكة الثالثة لتعلم التزينات التي تُغني عادةً الموسيقى الباروكية (لحن بشكل محدد).

حُللّت كامل المجموعة ضمن نوافذ ذات طول معطى – وبشكل محدد أكثر – لتعلم التوافقية أو الانسجام. تُغذى المعطيات المتعلقة بالسلسلة التوافقية من أجل ثلاثة نغمات ربعية سابقة في اللحظة t (أي التوافقية H في اللحظة t-1 وt-2 وt-3) إلى الشبكة سويةً مع السياق اللحني (أي اللحن M في اللحظة t-1 وt + 1)، بينما – كما هو مذكور سابقاً – تدير شبكتان آخرتان النغمة الجهيرة والتزيينات اللحنية.

تمت معالجة السؤال المتصل بأبعاد الشبكة بتطبيق خوارزمية تطورية من أجل أمثلة الشبكة العصبونية (ENZO معتمدة على مبدأ البقاء للأصلح): يتم الإبقاء على تشكيلة الشبكات العصبونية التي تعطي النتائج الأفضل، بينما تُزال الشبكات التي تعطى نتائج سيئة. لقد حكم الموسيقيون المحترفون على الترتيلات المؤلفة من قبل HARMONET بأنها مقنعة كلاسيكياً. الباحث Hörnel هو أحد أكثر الباحثين وافري الإنتاج في هذا المجال (Hörnel, 1998).

كما اُستعمل أيضاً إطار العمل الاتصالي من قبلِ Bosi et al, (2003) لاستقصاء توقع واكتمال سلاسل موسيقية مقتبسة من ترتيلات باخ، وقُورنت بإداء الخبراء البشر (الملحنين). يحسب المؤلفون من أجل: (1) الاتساق بأسلوب باخ الموسيقي، (2) الاختلاف فيما يتعلق بخرج الشبكة العصبونية. تشتمل المجموعة المدروسة على عدد هام من الترتيلات في زمن 414. وفي جميعها تقريباً تتزامن النغمة الربعية الأولى مع الضربة القوية، وسلاسل أكثر من 14 نغمة ثمانية لا تُقدم أبداً (الترتيلة BWV 248). توجد في تلك المجموعة تزيينات لحنية مميزة (مثل volta على سبيل المثال)، يمكن أن تعزى إلى حدوث تنافر ما. تكون التوافقية بسيطة: بعض مسارات الترتيلة، التي قد تبدو معقدة من أول نظرة، هي في الحقيقة تعاقب متميز من الإيقاعات كما أشار إليه Steinitz (1991). قام المؤلفون في تجاربهم بتزويد كل خبير بشري بنسخة من مقتطف (قضيب 13 إلى القضيب 16) لترتيلة Es Woll uns Gottgenadig Sein (BWV 311)، وطولب الخبراء

بإكمال ذلك الجزء، الذي كان مجهولاً من ناحية الملحن، ونوع القطعة الموسيقية. وكانت النتائج مثيرة جداً. لقد أنجز كل الخبراء المهمة بالطريقة المرتبطة بأسلوب باخ. على أية حال، أشار المؤلفون إلى بعض الضربات الخفيفة، التي تبدو أحياناً غير ملائمة كلاسيكياً: الصوت الخاطئ، والتوافقية الخاطئة، الإيقاع النهائي الخاطئ، والمقطع الموسيقي الكامل، الذي يصدر صوتاً في أسلوب الترتيلة "القديمة" (أي صوتي متماثل وإيقاعي متماثل). مع ذلك، أُخذ اللحن الأصلي في الحالة الأخيرة في الواقع من Geistliche gesang Buchlein، وأُختيرت المتقطفات من الترتيلات (1524) من قبل Luther وWalter، وبالتالي أقرب إلى الأسلوب الشعبي من عصر النهضة الموسيقي المتأخر (تحديد متميز بين المقاطع الموسيقية ... الخ). يعتبر المؤلفون مهمة الاكمال اللحني من ناحية توقع اللحن المستقبلي والأحداث التوافقية نتيجةً لتحليل معطيات متوفرة وثيقة الصلة (أي الجزء من قبل باخ). هذه مهمة ثنائية الطية بما أنها تتضمن:

1. النظر إلى الماضي وملاحظة أي المتغيرات هي مؤشرات هامة لسلوك المتغيرات الأخرى.
2. الحصول على فهم أفضل لأي المتغيرات هي مهمة للمراقبة كإشارات للتطورات الأخرى.

بشكل واضح، إذا عرفنا النموذج الحقيقي الضمني، الذي يولد المعطيات التي نرصدها، سنعلم كيفية الحصول على التوقعات الأفضل. ومع ذلك، قد يكون النموذج الحقيقي الضمني معقداً جداً حتى في ترتيلات باخ، بحيث أننا لا نكون متأكدين أي نموذج – من بين عدة نماذج متنافسة – هو النموذج الحقيقي. حتى في الحالة لـــ Bosi et at (2003)، فقد دُرست طريقة اتصالية مناسبة لهذه المهمة. يستخدم المؤلفون في تجاربهم شبكة تكرارية متأخرة زمنياً (TLRN)، تشبه بشكل كبير شبكة Pereceptron متعددة الطبقات موّسعة بتراكيب ذاكرة، لها اتصالات تكرارية محلية. في الحقيقة، تم إظهار أن TLRNs هي نماذج مناسبة لمعالجة المعلومات المتغيرة زمنياً (راجع Principe, Euliano, & Lefebvre, 1999، الصفحة 544). تقترح الإيقاعات أطوال المقاطع الموسيقية، التي تُغذى فيما بعد إلى الشبكة. يوافق المسار من أحد الإيقاعات إلى الآخر طولَ نظم ما (قصيدة ما) مع بعض الاختلافات بين الإيقاعات المدروسة:

1. ينهي الإيقاع الأصيل بشكل حاسم تقريباً العبارة الأخيرة لجملة تامة، ويُمثل بالمتوالية التوافقية V-I.
2. يحدث إيقاع نصفي في منتصف جملة موسيقية تامة وتنتهي نموذجياً عبارة داخلية، يُمثل هذا الإيقاع بعدة متواليات توافقية I-V، IV-V، ii-V، وvi-V، وتكون طبيعتها الوصول إلى الصفة الغالبة.

3. الجملة الموسيقية التامة هي جملة موسيقية كاملة، تتألف من عبارتين: تؤدي الأولى إلى إيقاع نصفي، وتؤدي الثانية إلى إيقاع أصيل.
4. العبارة هي جملة موسيقية تؤدي إلى إيقاع ما.

تُغذى الشبكة بالنصف الأول من جملة تامة ما، ويجب أن تتوقع النصف الثاني. يتعلق توقع المعلومات ببارامترات مختلفة: (1) صنف الموضوع، (2) المظهر الجانبي اللحني. (3) المجال التوافقي. شملت مجموعة التدريب على عبارات مقتطفة من 348 ترتيلة رباعية الصوت من قبل J.s.Bach. بعد تدريب الشبكة، اختبر المؤلفون أداء الشبكة على 20% من المعطيات، التي لم تُدرب الشبكة بها. ويمكن أن يُستخدم الانتشار الخلفي المباشر للتدريب، باعتبار أن الشبكات التكرارية يجب أن تكون مُدربة باستخدام خوارزمية تدريب ديناميكية. استخدمت خوارزمية الانتشار الخلفي خلال الزمن (BPTT) (Principe et al., 1999)، التي هي معقدة جداً، ولها عيب تطلّب الكثير من الذاكرة. من أجل حساب الطبيعة الخاصة للدخل الموسيقي، يضيف المؤلفون ذاكرة معاودة للماضي من إشارات الدخل. وبالتالي، يُحسب كل مأخذ ذاكرة ضمن شعاع المعطيات بنسخ بسيط للقيمة من المأخذ السابق لشعاع المعطيات المتأخر. وهذا يعني بأنه يُحسب أي مأخذ معطى ضمن شعاع المعطيات بأخذ جزء من القيمة من المأخذ السابق لشعاع المعطيات المتأخر، ويُضاف مع جزء من نفس المأخذ. تكون الوحدة الأولى لكل قناة ببساطة مدخل القناة ولا تُعدّل. وإن يعتبر المؤلفون جهدهم فقط دراسة تمهيدية، تبدو النتائج لتُظهر بأنها من أجل البشر تأخذ جهداً أقل بكثير لتصبح ماهراً في بعض الأساليب الموسيقية المعينة (أسلوب باخ في هذه الحالة) بالاتصال مع مهمات التنبؤ/الإكمال. السؤال المهم الذي يربك المؤلفون يشير إلى الحقيقية بأنه مع أي شيء ستُعتبر مجموعة تدريب نادرة جداً لأي شبكة (فقط ترتيلتان). كان الخبراء قادرين على إنجاز المهمة في نمط متوافق أسلوبياً، يُصغر الشبكات بموضوعية، وهي ما تزال تحتاج لمجموعات تدريب ضخمة وأزمنة حساب كبيرة.

تُستخدم شبكات Jordan-Elman من قبل الباحثين Gang, Lehman, & Wagner (1998) لحل أي مسألة تقدم بعض التشابهات الجزئية مع العمل لكل من Hörnel (1998) و Bosi et al (2003). وهم يطبقون وحدات سياق مع تغذية عكسية محلية لتأمين ذاكرة وتخزين الماضي الجديد، بما أن التغذية العكسية تكون عادةً ثابتة، فيمكن وضعها في أي مكان في شبكات Perceptron متعددة الطبقات بدون تغير طبيعة الانتشار الأمامي للتعلم. ربط المؤلفون وحدات السياق إلى طبقة دخل MLP نظامية لتأمين ذاكرة من معطيات الدخل الجديدة. يُضبط عمق الذاكرة في كل وحدة سياق من خلال تغذيتها عكسياً من جديد أو بثابت زمني. في هذه الحالة المعينة، تستخدم شبكات Jordan من أجل مهمات توافقية: طرح المؤلفون سؤالاً مثيراً جداً فيما يتعلق بمهام

التوافقية (أي توافقية النظرة الأولى). ولذلك، فإنه ليس سؤلاً عادياً، بما أنه يوجد عدد من المهام – التي يهتم بها الموسيقيون – حيث يكون ضرورياً ارتجال تخصيص أوتار لخط لحني جهير معين. وأحد الأمثلة هو basso continuo. يدعى Continuo أيضاً بالطبل، وهو بالحقيقة نظام المكمل المرتجل جزئياً والمعزوف على خط جهير عادةً على أداة مفتاحية، وكان مألوفاً خلال القرنيين السابع عشر والثامن عشر، وأعطى مرونة كبيرة لعازف الأدوات المفتاحية – الذي هو عادة عازف الأرغ أو عازف البيانو القيثاري – في تخصيص الأوتار.

التوافقية البصرية (التي تضبط الأوتار بشكل ارتجالي عند القراءة البصرية للحن ما) هي مهمة معقدة، شرط أساسي للتوافقية البصرية هو معرفة أساسيات التأليف الموسيقي. في الحالة اثناء جلسة ضبط الوزن، على سبيل المثال يتقاسم الموسيقيون كمية معينة من المعلومات المتعلقة بالمسارات التوافقية كي تتبع. وهذا يعني، بأن بناء نموذج بشري من أجل توافقية واقعية للألحان غير المشهورة يجب أن يتكامل مع كلٍّ من المعلومات المتسلسلة والزمنية. وسيكون شرطاً أساسياً. الوعي لموقع التسلسل الهرمي الموزون، والتأليف، والتوقعات اللحنية، والتوافقية والتخفيض، يطبق المؤلفون خوارزمية انتشار خلفي، وزودت شبكة فرعية المعلومات الموافقة لوزن الألحان. تتعلم الشبكة أيضاً سلسلة من الأوتار فيما يتعلق بنغمات اللحن وموقعها الوزني. تستقبل طبقة الدخل المعطيات المتعلقة بالخط اللحني، بينما تخرج طبقة الخرج نوع الوتر (هي تجسدّ 14 وتر: 7 ثلاثيات رئيسية – تُعّرف الثلاثيات في الموسيقى النغمة كأوتار ثلاثية النغمة، لها درجة أصل، الثالث فوق الأصل والخامس فوق الأصل – و7 أوتار سابقة – الأوتار السابقة هي تقريباً ثلاثيات مع نغمة فاصل السابع مُضافاً فوق الأصل). تمثل إحدى الطبقات الخفية الدرجات التوافقية، وهي متصلة بطبقة الخرج، بحيث تخلّق نوعاً من القيد بين النغمة والوتر الذي يكون معيناً. درب المؤلفون الشبكة بـــ 18 لحن، وابلغوا عن تعلم ناجح، كما أنهم يعتقدوا بأن نمذجة الإدراك الموسيقي بواسطة الشبكات، يمكن أن تحجب الضوء عن كيفية استخدام المعرفة الموسيقية بدقة من قبل الموسيقيين عند القيام بتنسيق بصري للحن ما.

ANNs وتحليل الموسيقى

ANNs من أجل نمذجة الإدراك الموسيقي

تم استقصاء أحد الاستعمالات الأكثر احتمالاً لــ ANNs (كما هو مذكور بشكل مختصر في الفقرة التمهيدية) من قبل أولئك العلماء المهتمين باستخدام المنصة، التي عليها تدرس وتبنى نماذج من الإدراك البشري. ولو أنها لا تربط بالضرورة مباشرةً مع كيف يمكن للبشر أن ينتجوا الذكاء. تم إنجاز مثال مثير من الدراسات الإدراكية التي تستعمل ANNs لنمذجة الإدراك البشري

في طريقة ما، بحيث تكون ملموسة وواقعية من قبل الباحثين (Large, Palmer, and Pollack (999، ويعالج مسائل الألحان المكررة مع التغيير. بحيث لا تُعتبر مُقيدة بمجال الموسيقى، فإن مسألة الألحان المكررة مع التغيير تعتبر هامة بشكل خاص للعلم الإدراكي إجمالاً. نظراً للحقيقة، بأنه يُنشد إدراك علاقات معقدة بين إمكانيات الجنس البشري والثقافة في المعنى الواسع للمصطلح. الفرضية المسحوبة من المؤلفين هي أن ينتج المستمعون تمثيلات داخلية لسلاسل موسيقية، وأثناء القيام بذلك يقيّموا ضمنياً الأهمية التركيبية للأحداث بعزو أهمية أكبر لبعض الأحداث وأقل لأحداث أخرى.

وهو هذا التابع الوظيفي للعلاقات التي يسمعها المستمعون، على سبيل المثال، بين لحن موسيقي وتكراراته مع التغيير، ويضمن ذلك بأنه بطريقة ما يكون أي مستمع قادراً على استخلاص السمات ذات الصلة للموسيقى بالتنقيب خلال المستويات المختلفة للمعلومات الموسيقية. نظرية العالم Schenker (1956)، على سبيل المثال، هي نظرية الاختزالية لعلم الموسيقى، بما أنها تقترح أنه يمكننا الاستمرار بتعرية الطبقات من الموسيقى بغية إيجاد النقص، الذي يقيس مقاطع أكبر وأكبر من قطعة ما.

يتميز نموذج العالم Schenker بثلاثة طبقات (مستويات) مختلفة من تركيبة موسيقية. إن النظريات الاختزالية مفيدة لتوضيح التغييرات الموسيقية، طالما أنها تفترض وجود نوع معين من التشابه للتراكيب الضمنية في الألحان ذات العلاقة. يجب أن يسمح هذا الاجراء تماماً للمستمعين بإدراك الانتظامات الإحصائية لثقافة موسيقية خاصة، أو أسلوب السؤال (Knopoff & Hutchinson, 1983، Palmer Krumhansl, 1990). يلزم بعض الاعتبارات الهامة عند هذه النقطة: الحقيقة أن الأوصاف المخفضة تتطلب معرفة الثقافة النسبية. ويعني الأسلوب، بأنه يوجد للحساب مكون تعلّم هام، يلتقط المستمعون الانتظامات بالاستماع إلى الانماط الموسيقية، وتحدد التمثيلات الإدراكية اللاحقة الحقيقية، بأن المستمعون يجردوا ويخزنوا نماذج أولية للأساليب الموسيقية، التي تؤدي إلى التوقعات الموسيقية. لهذا السبب، يقترح المؤلفون نموذجاً قادراً على إنتاج تمثيلات ذاكرة مُخفضّة للموسيقى ويعتمد على السلاسل، بحيث يخفض النموذج الأوصاف بعد ذلك. وتم بلوغ ذلك بالتمثيلات الموزعة المعاودة والتشكيل الاتصالي، الذي يسمح بتمثيل المعطيات الرمزية على هيئة أنماط من التفعيل لشبكة ما. العنصر الهام الذي يؤكد نية المؤلفون لاستخدام الاتصالية لإدراك النموذج هو المكون "التجريبي" لبحثهم الذي، تُحلل فيه التغييرات (ألحان تكرر مع التغيير) المُنفذة من قبل خبراء بشر، وتُقارن مع توقعات معتمدة على مبادئ الاختزالية، تُظهر شبكة عصبونية (مُدربة لإنتاج تمثيلات موزعة معاودة من أجل نفس تلك المجموعة من الألحان) شكلاً من التعلم، وتُعتقد لنمذجة الآلية التي – من جهة – تسمح للمستمعين باكتساب المعرفة من خلال التعرض للموسيقى – من جهة أخرى – وتسمح لهم بتجميع تمثيلات الذاكرة المخفضة للسلاسل الموسيقية.

ANNs من أجل تمييز نوع الموسيقى والأسلوب الموسيقي

يستحق موضوع تميز الأسلوب بواسطة الشبكات العصبونية إشارة خاصة، لأنه يشكل جهداً قيّماً للتفسير النظري لأي ظاهرة، ما يزال علم الموسيقى غير قادر تماماً على تحديدها.

يمكن أن تُعتبر عملية التمييز الأسلوبي كعملية تعلّم مُراقب - أي - يمكن أن يُعطى المستمع قطعاً متعددة من الموسيقى في أسلوب محدد (الأمثلة) سويةً مع قطع أخرى، لا يمكن أن تكون منسوبة إلى نفس الملحق أو العصر. ويمكن أن يعتقد هذا الأخير بأنها من غير الأمثلة.

من المعلوم جيداً بأن الشبكات العصبونية تعمل بشكل ممتاز مع التعلّم المُراقب: يمكن أن تُغذى أي شبكة بمرورات من قبل ملحنين معينين (أو حتى بأنواع كما سنرى)، وتُدرب لتصنف بشكل صحيح الأمثلة وغير الأمثلة (Buzzanca, 2002a). إذا تم إتمام عملية التعلّم بنجاح، فإن الشبكة تكون قادرة - في هذا الطور - لتمييز الموسيقى من ملحن ما من تلك الموسيقى للملحنين الآخرين (أو قطعة من الموسيقى، أو أحد الأنواع من بين الأنواع الأخرى، Ponce de León et al., 2004). الفائدة الأخرى التي تستحق الذكر، هي أن ANNs تسمح لكشف المقومات التركيبية العميقة والتصنيف اللاحق، كما أنه يفوق طرق AI التقليدية أداءً كما سنشرح معمقاً في الفقرات القادمة (راجع Buzzanca, 2002). يبدو أن البحث مركز على طريقتين رئيسيتين: (1) تمييز الأنواع المختلفة (أي الجاز من الكلاسيكي)، (2) تمييز الأساليب المختلفة.

حاول الباحث Birmingham et a.l (2001) تمييز الأسلوب الموسيقي: ينتقد المؤلفون تلك الطرق السابقة التي درست ترميز عناصر المستوي المنخفض (على سبيل المثال، الدرجات والممدد). وتمّ تجاهل عناصر المستوي العالي في عدد كبير من الحالات. بما أنها قد يبدوان غير منتظمين جداً وعشوائيين (على سبيل المثال، إذا استخدم ترميز MIDI، وMIDI هي اللفظة الأوائلية للواجهة الرقمية للآلات الموسيقية، راجع Selfridge - Field, 1997). يجرب المؤلفون مع التمييز أربعة أساليب مؤدية مختلفة (على سبيل المثال، قيثاري، شديد الاهتياج، رخم، وPointillistic).

وهدفه هو امتلاك آلية تنفذ التمييز بشكل صحيح لعدة قطع موسيقية، تكون كل قطعة مُنفذة في أسلوب مختلف. عُزفت عينات موسيقى من قبل مؤديين بشر، يقرؤوا على شاشة الأسلوب الواجب عليهم العمل وفقه. بعبارات أخرى، يجب على المؤدي أن يعزف بأسلوب الأداء المعروض على الشاشة. إذا تم إظهار قيثاري على الشاشة، فإنه سيعزف الموسيقى في نمط قيثاري. وإذا عرضت الشاشة فجأة أسلوباً مختلفاً - شديد الاهتياج على سبيل المثال - فإنه سيحول أداءه إلى الأسلوب شديد الاهتياج... وهكذا تُحال العينات المختلفة إلى المؤدي، بحيث يمكنه أن يؤكد بأن القطعة من الموسيقى التي سُمعت صحيحة، ثم أنها أديت فعلاً بالأسلوب الذي كان يُقصد أن تُعزف به. بما أن التغيرات في أداء الأسلوب قد أُظهرت على الشاشة بدون

إعطاء أية ملاحظة للمؤدي، فإن الثواني الأربعة الأولى تُنبذ، بينما تحتجز الثواني اللاحقة لضمان بأن العينة تُمثل بشكل موثوق الأسلوب المؤدى الموافق.

يستعمل المؤلفون مجموعة تدريب مؤلفة من 1.200 ثانية، تُغذى فيما بعد إلى الآلة في صيغة MIDI. تعتبر الآلة 13 بارامتراً منخفض المستوى (درجات، ممدد، جهارة الصوت، ... الخ). تُقارب النتائج لطرق التصنيف المختلفة (Bayes، مُصنّف خطي، شبكات عصبونية). تفوق النتائج من الشبكة الآخرين أداءً، مظهرةً بأن الشبكات العصبونية، يمكن أن تُستخدم لبناء مُصنّفات أسلوب موثوقة. تقترح الاستنتاجات المُستخلصة من قبل المؤلفين، بأن تقنيات تعلم الآلة - وبشكل خاص - الشبكات العصبونية نجحت بشكل جيد، بينما فشلت الطرق الأخرى، وذلك لأنها قادرة على الاعتبار عدد كبير من البارامترات المختلفة متعددة الأبعاد (درس المؤلفون 132 من الخصائص المختلفة).

القضايا الخاصة حول الموسيقى وANNs

ترميز الموسيقى

الموضوع المهم هو كيفية ترميز الموسيقى: يمكن لأي شبكة - في الحقيقة - أن تُغذى اما ببعض الموجة الصوتية (في هذه الحالة، سيكون من الضروري تحديد أيٍّ من المكونات المختلفة للصوت الفيزيائي تكون حاسمة للتمييز)، أو ببعض التمثيلات الدقيقة والمركبة عالية المستوي للموسيقى (راجع Buzzanca, 20026). في أي حالة، يكون تقطيع العبارات الموسيقية مهمة غير عادية، لأنه عنصرٌ حاسمٌ أيضاً (راجع Buzzanca, 2002b). يقترح الباحث Capinteiro (1995) ثلاثة طرق مختلفة لتقطيع الموسيقى: يكون الأول بتحديد مكان الوقف في التوافق مع مدة طويلة ضمن مجموعة من النغمات. أما الثاني فيكون بتحديد مكان الوقف حيثما توجد التوقفات المؤقتة. أما الأخير فيضع الوقف ضمن مجموعة من النغمات حينما تكون المجموعتان الفرعيتان، اللتين يمكن أن تُقسم المجموعة إليهما، موجودتان مع مدد متساوية في كل مجموعة فرعية وبنفس الوقت مدد مختلفة بين المجموعة الفرعية الأولى والثانية (على سبيل المثال، مجموعة من النغمات مؤلفة من ستة نغمات، ثلاثة أصوات شبه متهدجة، زائد ثلاثة أصوات متهدجة، في هذه الحالة يتجه الوقف يميناً بعد النغمة الثالثة).

ما أن يُقرر اجراء التقطيع، يكون العنصر المهم الآخر هو ترميز البارامترات الباقية (درجات، مدد، ... الخ)، ميّز الباحث Carpinteiro بين نغمة مذاعة (نغمة عزفت فعلاً) ونغمة مربوطة (نغمة لها درجة ولكنها في الواقع لا تُعزف بما أنها إطالة لنغمة سابقة)، والتوقف المؤقت (لا يوجد صوت على الإطلاق). وقام بترميزها كالآتي 11، 01، 00 على الترتيب. تم في تجربته

تطبيق كل جزء من الجزأين الإبداعيين لباخ كخط لحني واحد (تعمل الشبكة بشكل أحادي الصوت، بمعنى خط لحني واحد كل مرة بدلاً من متعدد الصوت). يؤكد بحث الباحث Carpinteiro بأنه يمكن لأي شبكة عصبونية تطبق تدريباً مُراقباً، أن تتعلم بكفاءة كيفية تقطيع العبارات الموسيقية.

قام الباحثون Ponce de León & Iñesta Quereda (2003a) و Ponce de León et al. (2004) باستقصاء تمييز النوع الموسيقي. بما أن النوعين المختارين يمكن أن يكونا مختلفين جداً عن بعضهما البعض (جاز وكلاسيكي)، فإن ارتباكاً طفيفاً على الدرجة الأصلية لتعقيد مهمة التصنيف تستحق في رأينا أن تستقصي أكثر في هذه الحالة. مع ذلك، فإن عدة حلول ممتازة تجعل عملهم قيّماً. يطبق المؤلفون العلامات في صيغة MIDI قياسية، تتضمن المجموعة الكاملة 110 ملفات MIDI متعددة المسارات (بمعنى الملفات التي تحتوي على أصوات متعددة)، يُستخلص منها اللحن. بهذا الأسلوب، فإن التحليل مكون وظيفياً للصوت الوحيد، الذي نُزع سابقاً. يستخدم المؤلفون "مواصفات"، أُظهرت من "نوافذ" بعرض ملائم. رغم أن الباحثين في مقالتهم الأولى Ponce de León & Iñesta Quereda (2003a) لم يستخدما الشبكات العصبونية، فإنه يوجد عنصران ذوا أهمية خاصة جداً: (1) أهمية مسألة التقطيع، (2) اختيار الترميز الملائم من أجل المعطيات الموسيقية. يستحق اختيار MIDI استطراداً قصيراً. هناك طرق متعددة من أجل ترميز الموسيقى على الحاسب (Selfridge-Field-1997). مع ذلك، يجب إن تُختار طريقة الترميز بعناية بالارتباط مع سمات مثل الاختزان الكفوء وإمكانية الإعراب العالية. في رأينا، الاختلاف الأول هو أن إنتاج الموسيقى وتحليلها يتصرف بشكل مختلف بالارتباط مع تقنية الترميز المختارة. MIDI، على سبيل المثال، لا تشكل توافقية ثنائية بين الأعداد والنغمات: العدد 60 – على سبيل المثال – يُعرف منتصف C (العدد 61 يُعرف C حاد وD مسطح، 62D، 63D حاد ...وهكذا). ولكن بنفس الوقت، بما أن هناك نغمات تكتب بشكل مختلف (على سبيل المثال B مسطح وA حاد)، ولكن هما توافقياً نفس النغمة في السلم المعتدل.

لا تسمح MIDI بتعريف نغمة ما استثنائياً. وكنتيجة إذا مُرّر رقم MIDI 60 المذكور سابقاً إلى الحاسب من أجل عزف نغمة ما، فإنه سوف يعزف منتصف C. وعلى النقيض. إذا قرأ الحاسوب الرقم 60 لأننا نريده أن يميز الدرجة المطابقة، فإنه يصبح من المستحيل تصنيفه بشكل مفرد، لأن أحداً لم يستطع التأكيد بشكل إيجابي، إن كان الرقم 60 يمثل منتصف C أو B حاد أو مسطح مضاعف.

من الواضح بأنه بينما – من جهة – لا توجد نتائج إذا عُزفت موسيقى MIDI. يمكن أن يكون التحليل متأثر بتمثيل خاطئ ناجح للعرض الحالي. ما هو العرض للمجال MIDI من 60 إلى 64؟

وهل يمثل ذلك C-E الثالث الرئيسي؟ ومن أجل B الرابع المخفف الحاد E؟ من أجل الأكثر من B الخامس المخفف الحاد F المسطح؟ وليس من المعلوم إن كان بإمكان ذلك أن يغير نتائج التحليل، لقد بينا جزئياً بأنه يمكن أن يفعل ذلك (Buzzanca, 2002).

بالعودة الآن إلى قضية التقطيع، يجب علينا أن نبدي حيرة لطريقة النوافذ بطول محدد مسبقاً (Ponce de León & Iñesta Quereda, 2003). بينما يمكن أن تكون مقبولة لتطبيقات تعلم الآلة. فإنه يبدو لنا بأنها غير ملائمة لبناء الأنظمة الاتصالية، التي تطمح لنمذجة الإدراك الموسيقي. في الحقيقة، يُشكل تقطيع الموسيقى إلى قطع ذات عرض ثابت تبسيطاً بالمقارنة مع الحياة الواقعية، بما أن "بتر" المحفزات الموسيقية إلى سلاسل بطول محدد مسبقاً ليس واقعياً لا من الناحية الإدراكية ولا في مستوٍ تركيبي/نظري (راجع Sloboda, 1985; Smoliar, 1992).

يمكن إيجاد مناقشة كاملة أخرى لهذه القضايا في كتاب (Buzzanca. 2002)، الذي صمّم مُميّزاً أسلوبياً عصبونياً مُنفذاً باستخدام شبكة عصبونية ذات انتشار خلفي مع عدد من التقنيات المبتكرة لحساب الطبيعة الخاصة للدخل الموسيقي. لا تقوم تقنيات الباحث Buzzanca بأية افتراضات حول الجملة التامة أو الأسلوب الموسيقي المدروس، غير أن تجاربه رُكزّت على Patestrina والموسيقى متعددة الأصوات من عصر النهضة الايطالية. الشبكة العصبونية مُصمّمة بثلاثة أغراض رئيسية لحساب الدخل الموسيقي ذي الطول المتغير بأسلوب منتظم، ولنمذجة الطبيعة المرتبية للتمييز الموسيقي، ولاكتساب أهمية التدفق الاتجاهي في الموسيقى. يكمن في قلب طريقة Buzzanca تقنية الأوزان المشتركة المُطورة من قبل الباحث LeCun (1989). والفكرة بسيطة جداً. ففي أي شبكة عصبونية عادية، يوجد وزن قابل للتعلّم منفصل مرافق لكل حافة بين عقدتين. باستخدام الأوزان المشتركة، يتم إجبار العديد من تلك الأوزان لتكون واحدة بطريقة متناسقة. انظر المخطط على (الشكل 1).

لذلك، فإن كافة الأوزان والحواف المنتمية لنوع معين تُرافق بأنواع من الحافة بدلاً من الحواف الفردية. ومثال على نوع حافة في الشبكة هو الحافة من العقدة التي تمثل الفترة بين الضربة الثانية إلى الثالثة في ميزان موسيقي ما، إلى أي عقدة تلخص كامل الإجراء. سيكون لهذه العقدة نفس الوزن من أجل كافة الإجراءات. على أية حال، فإن الحافة من العقدة، التي تمثل الفترة ما بين الضربة الأولى والثانية، إلى العقدة من أجل كامل الإجراء ستكون مختلفة. تمتلك الأوزان المشتركة ميزات عديدة. كما لُوحظ في المجال السابق، فهي تكتسب حقيقة أن حوافاً مختلفة تمثل نفس المفهوم، وبالتالي، يكون التعلّم مشتركاً بين تلك الحواف. علاوة على ذلك، فمن المعلوم جيداً بأن تعقيد العينة لشبكة عصبونية – وبالتالي عدد أمثلة التدريب اللازمة للتعلّم بشكل صحيح – يكون وثيق الصلة بمفهوم البعد VC (راجع Vapnik, Levin & LeCun, 1994)، التي

تعتمد على عدد الأوزان المختلفة. تقلل الأوزان المشتركة كثيراً العدد الكلي للأوزان المختلفة. ومن هنا، كمية معطيات التدريب اللازمة. وهذا الأمر مهم جداً، لأنه يتطلب بنية شبكة معقدة لتمثيل أشياء رقيقة في الأسلوب الموسيقي، غير أنه لا توجد معطيات كفاية لتعلم شبكة عادية من التعقيد بدرجة كافية. تتعامل تقنية الأوزان المشتركة أيضاً مع قضية حجم الدخل المتغير. يوضع ببساطة – بينما يُسمح لعدد الحواف بالتغير مع حجم الدخل – بأن عدد أنواع الحافة – وبالتالي عدد العبارات – هو ثابت. بإعطاء عبارة موسيقية بطول معين، يُنشأ المؤلف ببساطة شبكة من حجم كاف لتمثيل كامل العبارة. سيُعلّم نفس الأمر من أجل عبارات من كافة الأنواع المختلفة. أي الأوزان المرافقة مع كلٌ من أنواع الحافة. وهكذا. فإن علامات الحذف في المخطط يمكن أن تُملأ بأي عدد من الإجراءات، لأن جميعها بتركيب مماثل. للحصول على تحليل متعدد المستويات يستخدم الباحث Buzzanca طبقات خفية متعددة، يلخص كلٌ منها المستوي السابق. تلخص الطبقة الخفية الأولى المعلومات في ضربة واحدة. تأخذ الطبقة الثانية خرج الطبقة الأولى وتلخص ضربتين. لاحظ أن الطبقة الثانية تمتلك في الواقع أربعة مدخلات. وذلك لأنه في الطبقة الأولى يُقدم نمطين: من بداية الضربة إلى نهاية الضربة، ومن نهاية الضربة إلى بداية الضربة. وبشكل مماثل في الطبقة الثانية تُرصد أنماط قوية وضعيفة وأنماط ضعيفة – قوية. والنظرية هي أنه قد يُوصف أسلوب معين بماذا يحدث في أسلوب آخر. ويستمر التدرج بطريقة مماثلة: يلخص المستوي الثالث أربعة ضربات... وهكذا. يحدد الباحث Buzzanca الشبكة في تجربته إلى ثلاثة مستويات. وللحصول على اتجاهية الموسيقى، أخذ المؤلف الخرج من المستوي الأعلى التسلسل الهرمي وغذاه إلى شبكة موجهة. تتألف الشبكة الموجهة من سلسلة من العقد، من بداية الموسيقى وحتى النهاية. حيث تعتمد كل عقدة على العقدة السابقة في التسلسل، وعلى عقدة المستوى الأعلى الموافقة في لتسلسل الهرمي.

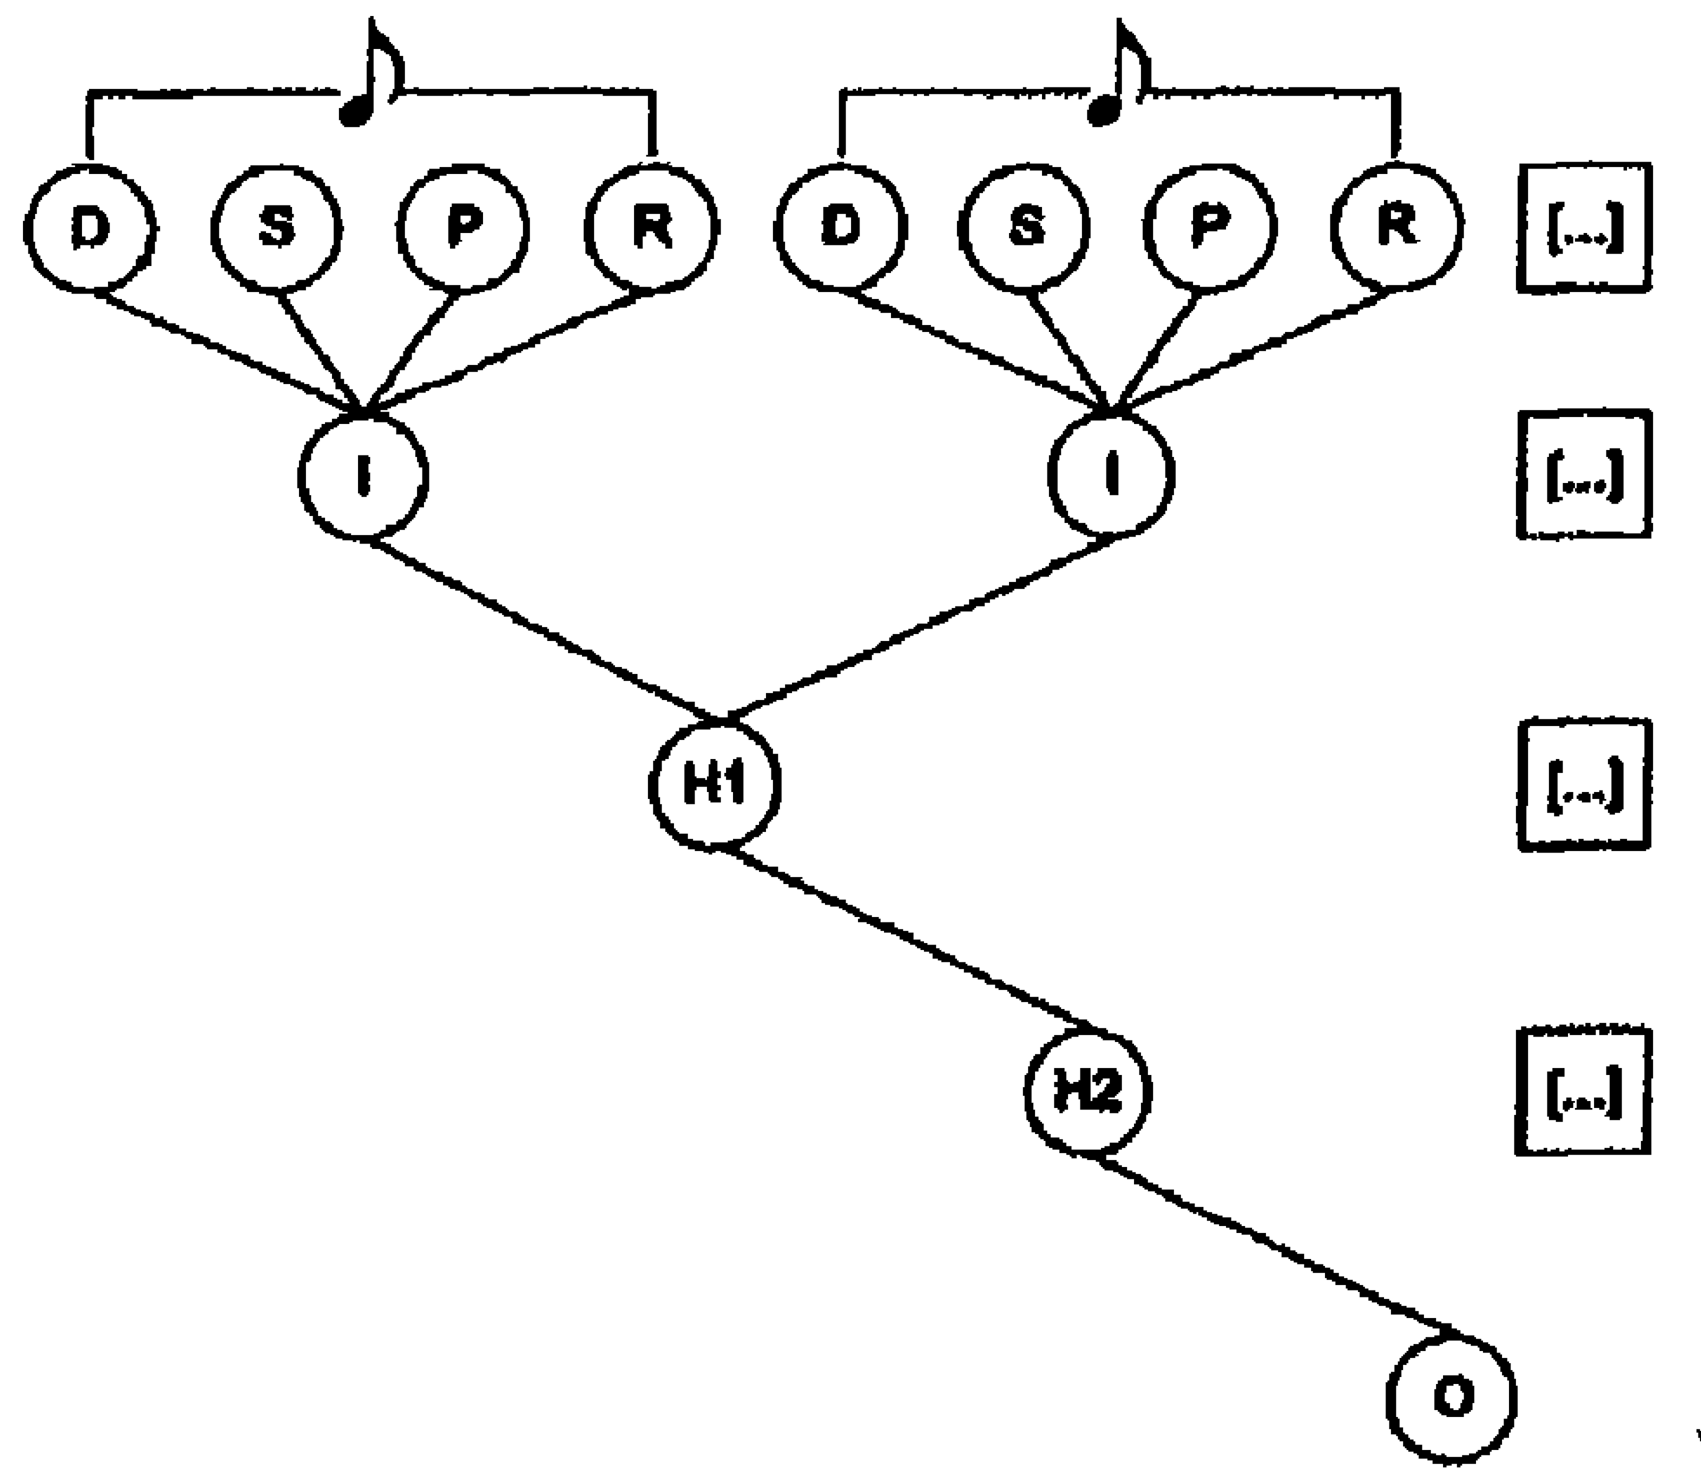
الرسم البياني في (الشكل 1) هو فقط مخطط الشبكة العصبونية. تمثل كل عقدة في الرسم البياني في الواقع مجموعة من العقد. تستخدم العقد الخفية نموذجياً بين عقدتين وستة عقد في كل نقطة. على سبيل المثال. قد يكون هناك أربعة عقد تمثل خلاصة القوي – الضعيف للمستوي الثالث. تمتلك كل عقدة مثل تلك دخلاً من كافة العقد الخفية للمستوي الثاني ذات الصلة. يتألف الدخل من أربعة عقد لكل وحدة موسيقى. وتكون الوحدة المختارة هي نصف ضربة (أي نغمة ثامنة من أجل موسيقى في زمن 414).

وهذه هي الوحدة الأصغر التي تحدث كثيراً في Palestrina، غير أن الطريقة تكيّف بسهولة إلى الوحدات الأصغر. بالرغم من أن النغمات الستة عشر تحدث من حين لآخر في Palestrina، فإن بناء شبكة من أجل تحليل ضربة ربعية، سوف يزيد التعقيد لدرجة كبيرة جداً لتبرير نمذجة هذه الأحداث العرضية بدقة.

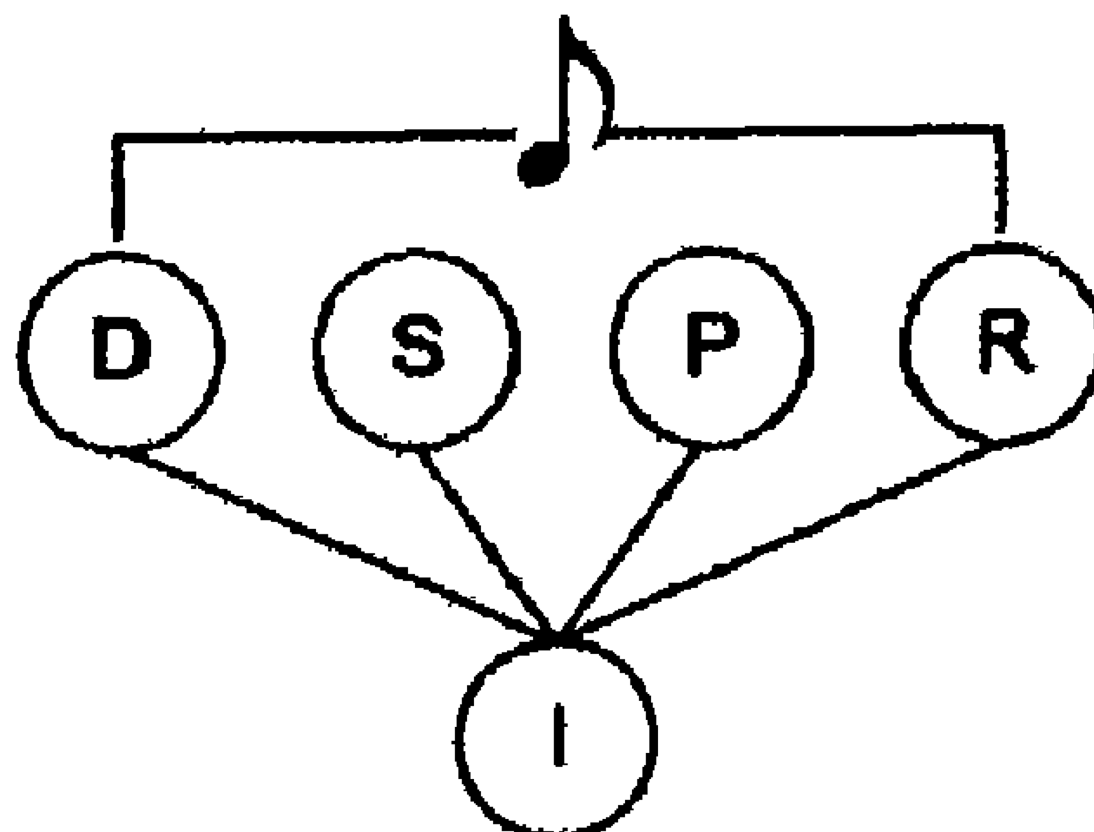
وكما يظهر، فما زال ممكناً التعامل مع النغمات الستة عشر بشكل جيد جداً كما هو مشروح لاحقاً.

خارج واحدات الدخل الأربعة لكل نصف ضربة، تُرمّز اثنتان المعلومات الإيقاعية وتُرمز اثنتان المعلومات اللحنية: يمكن أن يُدرس نظام الترميز هذا كأخذ عينات الموسيقى لكل نغمة ثابتة. الترميز الإيقاعي هو تعميم لما ذُكر سابقاً الناشئ عن الباحث Carpinteiro (1995).

الشكل (1) *مخطط النموذج الاتصالي من قبل الباحث Buzzanca (2002). تظهر الإشارة [...] إلى أنه يمكن إنماء النموذج إلى البعد المرغوب. يمثل الحرف I الدخل. ويمثل الحرف H الخفية، والحرف O من أجل الخرج. يشير السهم إلى تدفق المعلومات.*



الشكل (2) *تُرمّز واحدات الدخل الأربعة المعلومات المتعلقة بالمُدد والدرجات وسرعة نغمة ثامنة. تُرمّز الوحدة الأولى (D) المدة. وتُرمّز الوحدة الثانية (S) فيما إذا أذيعت النغمة أم لا (أي إذا كانت نغمة أم راحة). وتُرمّز الوحدة الثالثة (P) الدرجة، أما الرابعة (R) فتُرمّز المدى (أي الوثبة المتعلقة بالنغمة السابقة).*



تُرمز الوحدة الأولى بداية نغمة ما، وتكون قيمتها 0، إذا لم تبدأ نغمة في تلك اللحظة، وإلا تكون القيمة هي لوغاريتم المدة في ضربات نصفية (على سبيل المثال، 1 من أجل نغمة ثامنة، 2 من أجل نغمة ربعية، 3 من أجل نغمة نصفية ... وهكذا). يسمح هذا التمثيل لنا بترميز المدة، التي يُعتقد بأن تكون هامة في التعرف على الأسلوب، ولكن بطريقة ما بحيث تجعل تأثير النغمات الطويلة جداً أصغرياً. توافق الوحدة الإيقاعية الثانية إلى ماذا قد أذيعت نغمة ما في نقطة ما. وتكون 1 من أجل النغمات المذاعة، و0 من أجل الاستراحات. تُرمّز الدرجة بعقدتين. تُرمّز العقدة الأولى الدرجة المطلقة في أنصاف النغمات المتعلقة بالنغمة الأولى من اللحن، والثانية هي الدرجة النسبية إلى النغمة المُذاعة السابقة. بينما يوجد هنا حشو (إسهاب)، طالما أنه يمكن أن يُستدل على واحد من الآخر، فكلاها يكون مفيداً لتمييز الأسلوب. يعبر الأول عن السمات مثل المدى، الكفاف (الكنتور).

بينما يزود الثاني معلومات عن الفواصل. تظهر التجارب بالفعل، بأن تمثيل نفس المعطيات في طرق متعددة يمكن أن يكون مفيداً لمصنّفي شبكة عصبونية. كما يسمح لنا الترميز المضاعف للدرجة بالتعامل مع النغمات الستة عشر. تكون الأولى من اثنين من النغمات الستة عشرية عادةً أكثر أهمية، لذلك فهي تُستخدم لترميز الدرجة عند نقطة من النغمات الستة عشر. على أية حال، من أجل الدخل الفاصل للنغمة التالية، تؤخذ الثانية من اثنين من النغمات الست عشرية كالنغمة السابقة، بما أنها النغمة التي تحدد الفاصل. بهذا الأسلوب، يكون من الممكن اكتساب سمات مفتاحية لكلا النغمتين بدون الحاجة إلى نمو الشبكة كثيراً لملاءمة مقياس النغمة الستة عشرية.

التطبيقات الأخرى

خرائط التنظيم الذاتي (SOMs)

تمت معالجة تمييز الأسلوب الموسيقي أيضاً باستخدام خرائط التنظيم الذاتي (SOMs) للعالم Kohonen (Kohonen, 1989). ومن المعلوم أن SOMs هي شبكات عصبونية صنعية تحاكي عملية التنظيم الذاتي المنسوبة إلى الجهاز العصبي المركزي بخوارزمية عددية فعالة وبسيطة: تمتلك مصفوفة ثنائية البعد من وحدات المعالجة البسيطة شعاعاً مرجعياً مرتبطاً بكل وحدة. بعد التدريب بأشعة دخل، تنقل الشبكة بشكل لا خطي الدخل المتعدد البعد إلى المصفوفة بوضع الأشعة، التي تكون قريبة لشعاع آخر، في مناطق متجاورة من المصفوفة. استخدم الباحث Ponce de León et al. (2004) هذه التقنية للتمييز بين الجاز والموسيقى الكلاسيكية. من جديد، هم يرمزون الموسيقى في صيغة MIDI: أولاً، يفصل المؤلفون الخط اللحني عن بقية المعلومات

الموسيقية المحتواة في ملفات MIDI (يبقوا سلسلة فقط، إما نغمات أو استراحات، وتُزال أحداث MIDI الأخرى تماماً). تكون الأجزاء الموسيقية ثمانية إجراءات عريضة (في زمن 414)، تتضمن المجموعة الكاملة 430 عينة جاز و532 عينة لحن كلاسيكي. تبحث مقالات حديثة أخرى في قدرة SOMs ي مجال تمييز الأسلوب. ويمكن أن يكون للمقالة المنشورة من قبل Rauber and Frühwith (2001) مكاناً ضمن منطقة واسعة من الدراسات المسماة "تصنيف الإشارة الصوتية (ASC)". تهدف ASC إلى التنقيب عن سمات ذات صلة بأغراض التصنيف (راجع على سبيل المثال، (Gerhard, 2003)). يصبح التصنيف الآلي للموسيقى إلى أنواع هاماً أكثر فأكثر، بما أنه توجد كمية متزايدة هامة ومستمرة من الموسيقي المتوفرة على شبكة الانترنت (web)، التي هي السبب العملي بالإضافة إلى الأسباب "الأبرز" المُتصلة بتوسيع النماذج الواقعية من الإدراك البشري. لفهم أبعاد الموضوع، يكفي القول أن MP3.com تحتفظ بتسجيل لــ 350 نوع موسيقي مختلف.

طبق الباحثان Rauber and Frühwirth (2001) نموذجاً يمكنه تمييز لحن يُدندن من قبل المستخدم: وهذا ليس بمهمة عادية، بما أن كل مستخدم يمكن أن يدندن اللحن في تناسق أنغام مختلف (يحدث شيء مماثل مع تعلم إزاحة غير متغيرة بالشبكات). وبالتالي، يمكن أن تعيق المعادلة التمييز. تقسم ممرات الموسيقى إلى قطع ذات خمس ثواني. تُنبذت كافة البدايات وكافة النهايات لمنع تأثيرات خفوت الصوت لعرقلة التمييز. بعدئذ، تغذى إلى SOM وتوزع وفقاً لدرجاتها في التشابه.

الجدول (1) نتائج التصنيف (معدلات النجاح بالنسب المئوية) من أجل Ponce de León et al. (2004) يستخدم المؤلفون مجموعة من الواصفات اللحنية، والتوافقية، والإيقاعية، تظهر النتائج فروقاً في الأداء فيما يتعلق بعدد الواصفات المستخدمة. وجدت النتائج الأفضل من أجل كلا الأسلوبين بإيجاد المعدل لأسلوب الجاز والكلاسيكي. في السطر الثاني يمثل 8 × 16 و 12 × 30 حجم الخريطة.

	جاز				كلاسيكي				الاثنين			
	16×8		30×12		16×8		30×12		16×8		30×12	
الواصفة	الأفضل	معدل	الأفضل	معدل	الأفضل	معدل	الأفضل	معدل	الأفضل	معدل	الأفضل	معدل
الكل	89.8	72.7	87.8	61.2	93.2	79.6	85.1	70.8	90.8	76.1	80.7	66
6	98	79.4	81.6	68.4	95.2	82.1	90.5	89.3	92.5	80.8	78.3	73.3
7	96	81.8	83.7	74.1	97.3	86.5	97.3	76.6	96	84.2	85.1	75.4
10	98	78.8	87.8	63.3	96	82.7	90.5	74.6	88.8	80.7	89.2	68.9
13	87.8	72	89.8	67.1	97.3	82.6	85.1	68.8	84.4	77.3	78	68
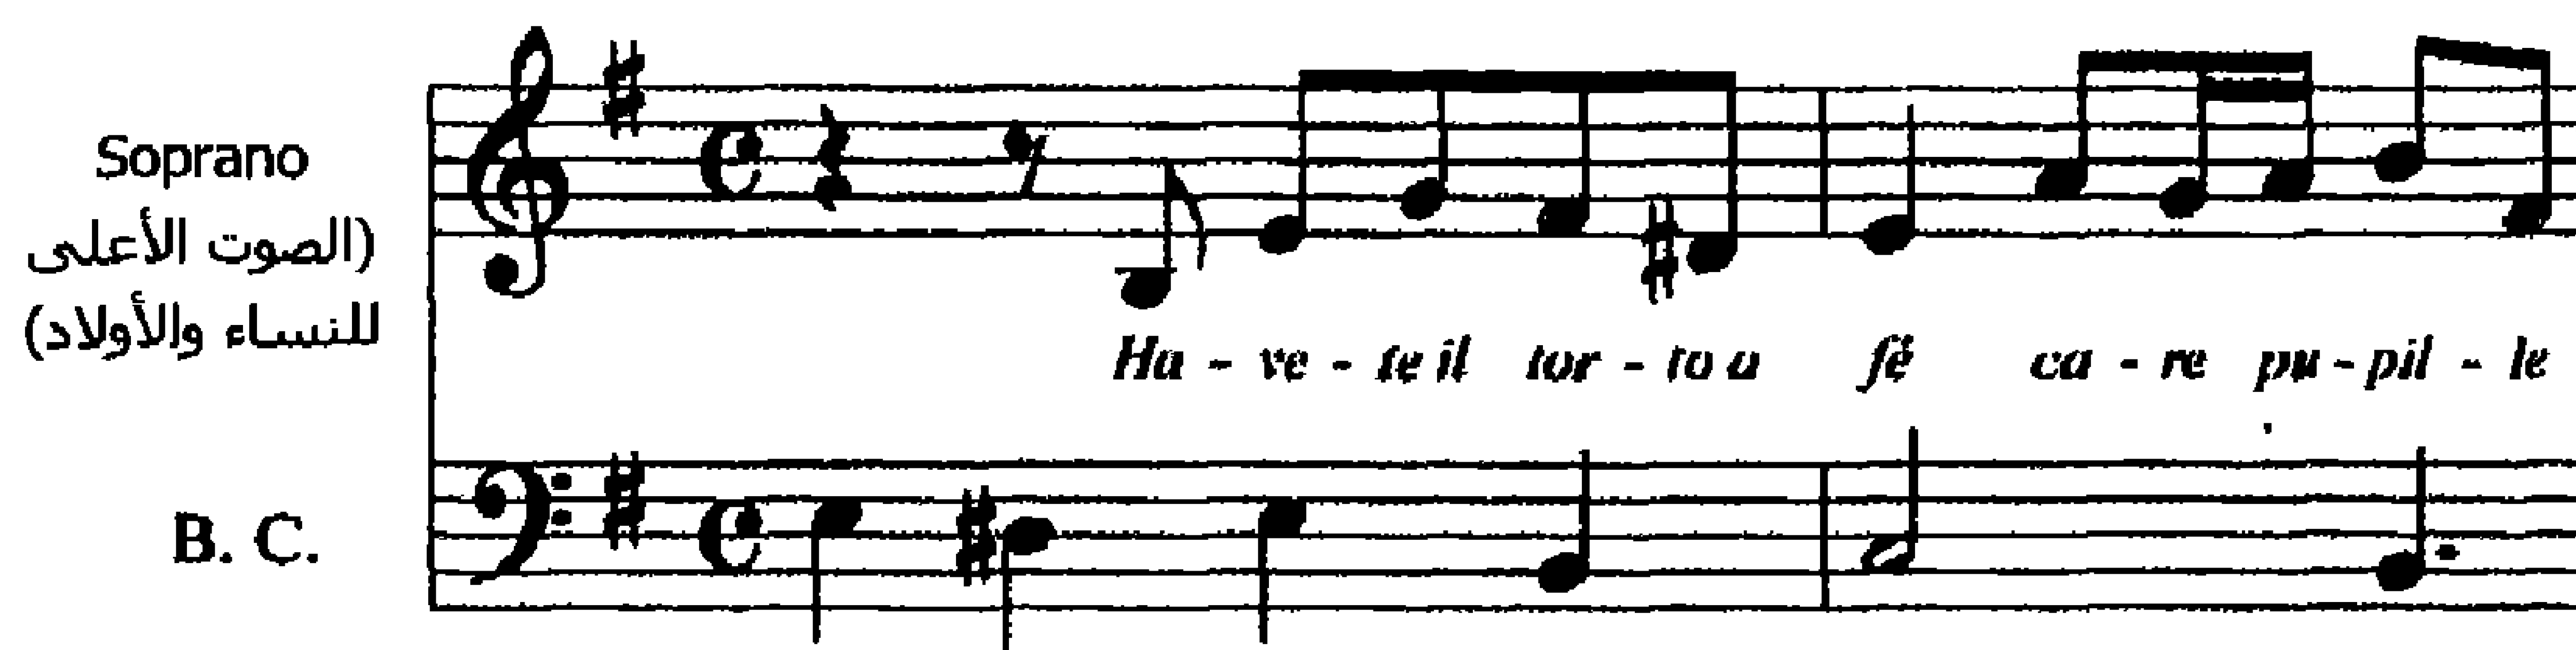
الشبكات العصبونية المعيارية

قام الباحث Buzzanca (2003) بتطبيق مُميّز أسلوبي، يستخدم صنفاً معيناً من شبكات Perceptron متعددة الطبقات (MLP)، المسماة أيضاً بالشبكات العصبونية المعيارية (MNNs). تعالج هذه الأنواع من الشبكات دخلها باستخدام عدة MLPs متوازية، ومن ثم إعادة دمج النتائج. تتضمن المجموعة الكاملة المُحللة عدة أنغام من قبل الملحن Giovanni Legrenzi (1626 - 1690)، وبعض الملحنين المعاصرين الآخرين: Alessandro Stradella (1639 - 1682)، Alessandro Scaratti (1660 - 1725)، Luigi Rossi وDomenico Gabrielli (1651 - 1690)، بالإضافة إلى الملحن الآلي LEGRE (Baroni et al, 1999)، لقد أظهر الباحث Buzzanca (2002a)، بأن تقنية الأوزان المشتركة تُقلل بشكل كبير العدد الكلي للأوزان المختلفة اللازمة (بالتالي، كمية معطيات التدريب). لذلك، فإنه ليس بتحسين عادي تصميم نماذج شبكة، لا تتعلّم بتعديل الوزن الفردي، بل بالأحرى تعتزم المناقشة والتعاون لنماذج مختلفة. يعتمد تطبيق النموذج على طريقة التقسيم، تُقسم أي مهمة إلى مهام فرعية صغيرة وأقل تعقيداً.

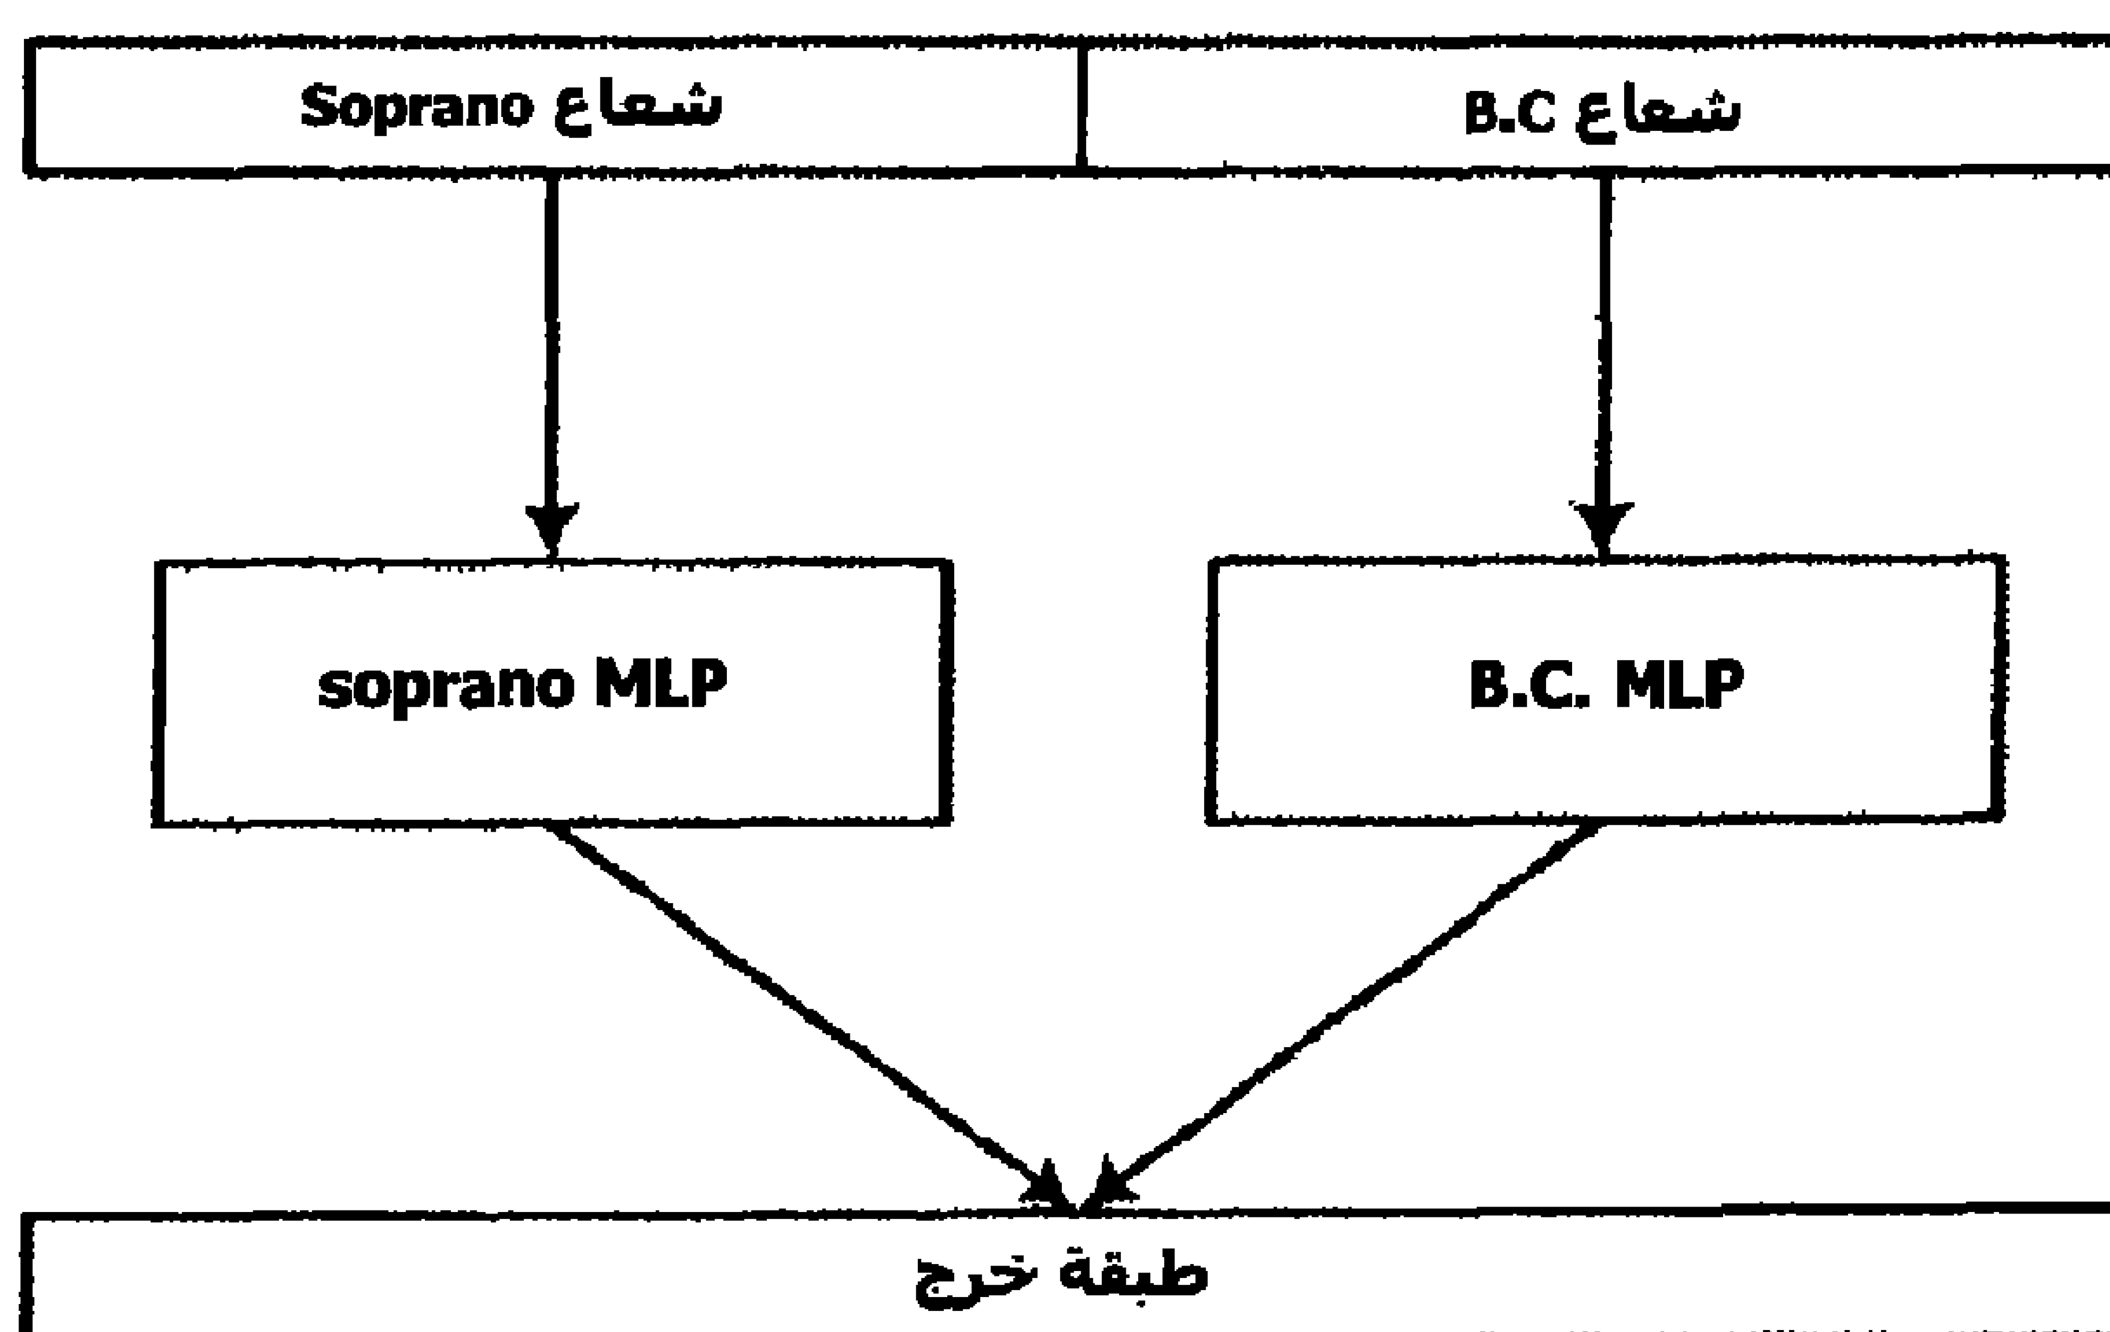
وهذا ينتج خبراء مختلفين (أي نماذج NN) يتعلمّون كل مهمة. ثم يمكن أن يُعاد التعلّم المُنجز من قبل كل نموذج فرعي لحل كامل المسألة. تُقطّع كل قطعة من الموسيقى إلى عدة قطع مختلفة (تسمى العبارات). بما أن أهمية النص تكون حاسمة في هذا النوع من الموسيقى، فإن كل تركيب يُقطّع في عبارات، لها نفس طول بيت الشعر، انظر (الشكل 3). ثم يُقسم التمييز إلى مهمتين فرعيتين: تمييز Soprano وB.C. تُدرب كل مهمة، ثم تُدمج لاحقاً في البنية الهندسية العامة وفقاً للمخطط التالي (الشكل 3). تنطبق كل قطعة من الموسيقى كتلك المبنية في (الشكل 3)، بحيث يوضع السلم الموسيقي العلوي جنباً إلى جنب مع السلم الموسيقي السفلي. وهكذا، ينتج شعاعان، كل واحد موافق لسلم موسيقي (الشكل 4).

من المخطط (الشكل 3)، يمكن أن نلاحظ أن كل مهمة تُدرب على حدة، ثم تُدمج لاحقاً في البنية الهندسية العامة. ويمّكن ذلك تسريع التعلم، تمتلك طبقة الدخل عدد كافياً من عقد الدخل، تُرمّز كل واحدة منها المدة لنغمة ثامنة، بالإضافة إلى معلومات أخرى عن الدرجة والمدة. عقدة الخرج مُقسمة إلى مجموعتين فرعيتين، كل واحدة منها مسؤولة عن مهمة Soprano، ومهمة Continuo على الترتيب. فيما يتعلق بالبنية الهندسية للشبكة المعيارية، فإن الطبقة الخفية تقسم إلى اثنتين ومتصلة محلياً مع عقد خرج Soprano، وعقد الخرج الأخرى Continuo. ويتم الحصول على النتائج الأفضل، عندما تُستخدم عقد خفية لحل المهمة الفرعية Soprano محلياً وعقدة خفية لحل المهمة الفرعية Continuo. وهذه النتائج مبينة في (الجدول 2).

الشكل (3) *قُطّع النغم إلى عبارات شعرية طويلة (أي أن العبارات الموسيقية طويلة بنفس طول الأبيات الشعرية للقصيدة، التي وُضعت في الموسيقى). في هذا النغم المعين (n.2). البيت الأول في القصيدة هو "Havete it torto afé care pupille" أي ("أنت مخطئ جداً يا حبيب العيون")، لذلك ينتهي التقطيع المُغذى إلى الشبكة عند النغمة الثامنة الموافقة للمقطع اللفظي الأخير من كلمة Pupille (أي '-Le'). سيكون، بالتالي، طول العبارة الموسيقية الثانية التي ستُغذى إلى الشبكة محدودة ببيت الشعر الثاني ... وهلم جراً.*



الشكل (4) *التمييز مُقسم إلى مهمتين فرعيتين بارزتين (أي تعلم Soprano وB.C).*



لجدول (2) تمييز الأسلوب: نتائج التصنيف (معدلات النجاح بالنسب المئوية). النتائج في هذا المثال المتعدد الصفوف مكتسبة بوضع جانباً 20% من الأمثلة للاختبار.

(%)	الملحن
98.5	GABRIELLI
88.2	LEGRE
72.2	LEGRENZI
96.2	ROSSI
84.2	SCARLATTI
89.1	STRADELLA

استخدم أيضاً الباحثان SOM Toiviainen & Eerola (2001) للتمييز بين الأغاني الشعبية من ألمانيا وشمال الصين. يستنتج المؤلفون بأن أحد التطبيقات الممكنة لطريقتهم هو استعمالها لكشف الاختلافات/التشابهات في الأسلوب في مناطق من العالم بعيدة جداً عنهم، لجعل هذه المعلومات متوفرة عند تخليق فرضية لمقارنة ثقافية مشتركة.

نغلق هذه المناقشة باقتباس عن الباحث Birmingham et al (2000): يكون التصنيف الأكثر دقةً مرغوباً في تمييز نوع الموسيقى والأسلوب الموسيقي بالشبكات العصبونية. مع ذلك، أصبحت تقنيات جديدة متوفرة بفضل نمو الاهتمام في هذا المجال.

الاستنتاجات

لقد بينا أنه يمكن للشبكات العصبونية أن تؤدي بشكل جيد المهام المعقدة في مجال الموسيقى. يبدو أيضاً أنها قادرة على حث السمات الخفية لمجال ما، قد يكون محّيراً، إلى طريقة معتمدة على القواعد.

يسمح التصميم المرن، الذي يصاحب الشبكات العصبونية بترميز التركيبة الموسيقية في نماذج معقدة، لكنها قوية.

لقد تم إظهار أنها ناجحة في عدد من المهام الموسيقية على حد سواء مثل تأليف الموسيقى، والارتجال، وتحليل الموسيقى، بما في ذلك مهام تمييز الموسيقى، وتمذجة الإدراك الموسيقي.

ملاحظة نهائية

1. من الآن فصاعداً، سوف نستخدم كافة المصطلحات كمترادفات، مع ذلك يوجد اختلاف في رأينا بين استخدام مصطلح الاتصالية (كنموذج في المعنى الكيوهني (نسبة للعالم Kuhn)، والشبكات العصبونية (كتقنية حسابية متكيفة لتعلم الآلة مثلاً).

2. يعبر عن المدة النسبية للنغمات الموسيقية من ناحية العلاقة البسيطة التي تحملها إلى نغمات أخرى. كلٌّ منها يمثل مدة أطول بمرتين من النغمة الأصغر التالية. إن مدة النغمة الثامنة أطول بمرتين من النغمة الموسيقية السادسة عشر. من أجل كل مدة نغمة موسيقية، هناك رمز مطابق يُدعى بالاستراحة، ويشير إلى مدة مكافئة من الصمت. في حالة الشبكات العصبونية، فإن حقيقية، أن طبقة الدخل تمتلك عادة عدداً ثابتاً من الوحدات – تمثل عائقاً جدياً، عندما يتعلق الأمر بترميز الإيقاع. في الحقيقة، حتى إذا تمكنت طبقة دخل افتراضية

من معالجة عدد من النغمات الموسيقية – ما مجموعه على سبيل المثال نغمة موسيقية كاملة – فإنه يوجد عدة مجموعات جزئية، تجمع النغمة الموسيقية الكاملة: تجمع الثامنة ثمانية نغمات موسيقية. أي نغمة موسيقية كاملة، وكذلك الأمر بالنسبة للسادسة عشر فهي تجمع 16 نغمة موسيقية. غير أن ذلك يعني في الحالة الأسبق، أننا نحن نحتاج إلى ثمانية وحدات دخل فقط، بينما في الحالة الأخيرة فإننا نحتاج إلى 16 وحدة دخل، وهذا هو سبب كون ترميز الإيقاع مسألة غير ملحوظة جداً.

3. النغم هو تركيب، يدمج الموسيقى مع أبيات شعرية من قصيدة ما، بحيث تذهب ألحان مختلفة سويةً مع أبيات شعرية مختلفة. وهكذا، توجد عدة طرق لتقطيع نغم ما: تكون التقطيعات بنفس طول البيت الشعري، والمقطع هو 8 نغمات موسيقية ثامنة ... وهكذا.

المراجع

Baroni, M., Dalmonte, R., & Jacoboni, C. (1999). Le regole delta musica. Indagine sui meccanismi delta comunlcavone. EDT.

Bharucha, J.J., & Todd, P.M. (1988). Connectionist learning of schematic musical expectancies. Bulletin of the Psychonomic Society, 26(6), 496.

Birmingham, W.P., Dannenberg, R.D., Wakefield, G.H., Bartsch, M., Bykowski, D., Mazzoni, D., Meek, C., Mellody.M., & Rand, W. (2001). MUSART: Music retrieval via aural queries. Proceedings of ISMIR 2001. Bloomington, IN (pp. 73-81).

Bosi, A., Buzzanca, A., Buzzanca, G., Gargiulo, A., & Lamanna, M. (2003). Melodic prediction with time-lagged feedforward networks. Proceedings of the 3rd Conference Understanding and Creating Music, Caserta, Italy (pp. 31-33).

Bresin, R. (2000). Virtual virtuosity. Studies in automatic music performance. Ph.D. thesis. Kung1 Tekniska Högskolan.

Buzzanca, G. (2001).A rule based model for musical style recognition. Proceedings of the 3rd Conference Understanding and Creating Music, Caserta, Italy.

Buzzanca, G. (2002a). A supervised learning approach to musical style recognition. Additional Proceedings of the Second International Conference ICMAI 2002, Edinburgh, Scotland.

Buzzanca, G. (2002b). A neural network model for musical style recognition. Proceedings of the 2nd Conference Understanding and Creating Music, Caserta, Italy.

Buzzanca, G., (2003). Uncovering musical style through modular feed-forward networks. Proceedings of the 3nd Conference Understanding and Creating Music, Caserta, Italy (pp. 48-52).

Camilleri, L. (1992). Computational theories of music. In M. Leman (Ed.), Computer representation and models in music. San Diego, CA: Academic Press.

Carpinteiro, O. (1995). A neural model to segment musical pieces. In E. Miranda (Ed.), Proceedings of the Second Brazilian Symposium on Computer Music, Fifteenth Congress of the Brazilian Computer Society (pp. 114-120). Brazilian Computer Society.

Cosi, P., De Poli, G., & Prandoni, P. (1994). Timbre characterization with mel-cepstrum and neural nets. In Proceedings of the 1994 International Computer Music Conference (pp. 42-45). San Francisco: International Computer Music Association.

De Poli, G., & Tonella, P. (1993). Self-organizing neural network and Grey's timbre space. In Proceedings of the 1993 International Computer Music Conference (pp. 260-263). San Francisco: International Computer Music Association.

Desain, P., & Honing, H. (1989). The quantization of musical time: A connectionist approach. Computer Music Journal, 13(3), 56-66.

Gang, D., Lehman, D., & Wagner, N. (1998). Tuning a neural network for harmonizing melodies in real time. Proceedings of the International Computer Music Conference, Ann Arbor, Michigan.

Gerhard, D. (2003). Audio signal classification: History and current techniques. Technical Report TRCS2003 07.

Hörnel, D., & Degenhardt, P.(l 997). A neural organist improvising baroque-style melodic variations. In Proceedings of the 1997 International Computer Music Conference (pp. 430-434). San Francisco: International Computer Music Association.

Hörnel, D., & Ragg, T. (1996). A connectionist model for the evolution of styles of harmonization. In Proceedings of the Fourth International Conference on Music Perception and Cognition (pp. 219-224).

Hörnel, D., & Ragg, T. (1996) Learning musical structure and style by recognition, prediction and evolution. In D. Rossiter (Ed.), Proceedings of the 1996 International Computer Music Conference (pp. 59-62). San Francisco: International Computer Music Association.

Hörnel, D. (1998). A multi-scale neural-network model for learning and reproducing chorale variations. Computing in Musicology, 11.

Janata, P., & Grafton, S.T. (2003). Swinging in the brain: Shared neural substrates for behaviors related to sequencing and music. Nature Neuroscience, 6, 682-687.

Kaipainen, M. (1994). Dynamics of musical knowledge ecology. Knowing what and knowing how in the world of sounds. Ph.D. dissertation. University of Helsinki, Finland.

Knopoff, L., & Hutchinson, W. (1978). An index of melodic activity. Interface, 7, 205-229.

Koelsch, S., Gunter, T.C.,Cramon, D.Y., Zysset, S., Lohmann, G., & Friederici, A.D.(2002). Bach speaks: A cortical "language-network" serves the processing of music. Neuroimage, 17,956-966.

Koelsch, S., Kasper, E., Sammler, D., Schuize, K., Gunter, T., & Friederici, A.D. (2004). Music, language and meaning: Brain signatures of semantic processing. Nature Neuroscience, 7,302-307.

Kohonen, T. (1989). Self-organization and associative memory. Springer Verlag.

Krumhansl, C.L., Toivanen, P., Eerola, T., Toivianinen, P., Jarvinen, T., & Louhivuori, J. (2000). Cross-cultural music cognition: Cognitive methodology applied to North Sami yoiks. Cognition, 76, 13-58.

Large, E.W., & Kolen, J.F. (1994). Resonance and the perception of meter. Connection Science, 6, 177-208.

Large, E.W., Palmer, C., & Pollack, J.B. (1999). Reduced memory representations for music. In N. Griffith and P. M. Todd (Eds.), Musical networks. Parallel distributed perception and performance. Cambridge, MA: MIT Press.

Lawrence, S., Giles, C.L., Chung Tsoi, A., & Back, A.D.(1996). Face recognition: A hybrid neural network approach. Technical Report, UMIACS-TR-96-16 and CS-TR-3608. College Park, MD: Institute for Advanced Computer Studies University of Mary-land.

LeCun, Y. (1989). Generalization and network design strategies. In R. Pfeifer, Z. Schreter, F. Fogelman, & Steels (Eds.), Connecfionism in perspective. Zurich.

Leman, M. (1988). Sequential (musical) information processing with PDP-networks. In Proceedings of the First Workshop on AI and Music (pp. 163-172). American Association for Artificial Intelligence.

Leman, M. (1989). Artificial neural networks in music research. Reports from the seminar of musicology. Institute for psychoacoustics and electronic music. University of Ghent.

Leman, M. (1990). Emergent properties of tonality functions by self-organization. Interface, 19,85-106.

Leman, M. (1991 a). Artificial neural networks in music research. In A. Marsden & A. Pople (Eds.), Computer representations and models in music (pp. 265-301). London: Academic Press.

Leman, M. (1991b). The ontogenesis of tonal semantics: Results of a computer study. In P.M. Todd & D.G. Loy (Eds.), Music and connectionism (pp. 100-127). Cambridge, MA: MIT Press.

Leman, M., & Carreras, F. (1996). The self-organization of stable maps in a realistic musical environment. Proceeding of The Journées d' Informatique Musicale, Caen, University ofCaen/IRCAM (pp. 156-169).

Linster, C. (1990). A neural network that learns to play in different styles. Proceedings of the 1990 International Computer Music Conference, San Francisco (pp. 311-313).

Lischka, C. (1991). Understanding music cognition: A connectionist view. In G. De Poli, A. Piccialli, & C. Roads (Eds.), Representations of musical signals (pp. 417-445). Cambridge, MA: MIT Press.

Loy, D.G. (1991). Connectionism and musiconomy. In P.M. Todd & D.G. Loy (Eds.), Music and connectionism (pp. 20-38). Cambridge, MA: MIT Press.

Maess B., Koelsch S.,Gunter T.C., & FriedericiA.D. (2001). Musical syntax is processed in Broca's area: An MEG study. Nature Neuroscience, 4, 540-545.

Medler D.A. (1998). A Brief History of Connectionism. Neural Computing Surveys, 1, 61-101.

Mozer, M.C. (1994). Neural network music composition by prediction: Exploring the benefits of psychoacoustic constraints and multi-scale processing. Connection Science, 6,247-280.

Mozer, M.C. (1991). Connectionist music composition based on melodic, stylistic, and psychophysical constraints. In P.M. Todd & D.G. Loy (Eds.), Music and connectionism (pp. 195-211). Cambridge, MA: MIT Press.

Newell, A., & Simon, H.A. (1972). Human problem solving. Prentice-Hall.

Ovans, R., & Davison, R. (1995). An interactive constraint-based expert assistant for music composition. Proceedings of the Ninth Canadian Conference on Artificial Intelligence, Ottawa, Canada (pp. 76-81).

Page, M. P.A. (1994). Modelling the perception of musical sequences with self-organizing neural networks. Connection Science, 6,223-246.

Palmer, C., & Krumhansl, C.L.(1990). Mental representations of musical meter. Journal of Experimental Psychology: Human Perception & Performance, 16, 728-741.

Patel, A.D. (2003). Language, music, syntax and the brain. Nature neuroscience, 6, 674-681.

Ponce de León, P.J, & Iñesta Quereda, J.M. (2003a). Musical style classification from symbolic data: A two-styles case study. Proceedings of the CMMR(pp. 167-178).

Ponce de León, P.J,& Iñesta Quereda, J.M. (2003b). Feature-driven recognition of music styles. Proceedings of the IbPRIA (pp. 773-777).

Ponce de León, P.J., Pérez-Sancho, C., & Iñesta Quereda, J.M. (2004). A shallow description framework for musical style recognition. Proceedings of the SSPR/SPR 2004(pp.876-884).

Principe, J.C., Euliano, N.R., & Lefebvre, W.C. (1999). Neural and adaptive systems New York: John Wiley & Sons.

Rauber, M., & Frühwirth (2001). Automatically analyzing and organizing music archives. Proceedings of the 5th European Conference on Research and Advanced Technology for Digital Libraries (ECDL 2001), Darmstadt, Germany.

Reck, M.E. (2000). Readings in music and artificial intelligence. Harwood Academic Press.

Rumelhart, D.E., & McClelland, J.L. (1986). Parallel distributed processing: Explora-tion in the microstructure of cognition. Cambridge, MA: MIT Press.

Schenker, H. (1956). Der freie Sati. Universal Edition.

Selfridge-Field E. (Ed.) (1997). Beyond MIDI. The handbook of musical codes. Cambridge, MA: MIT Press.

Sloboda, J. (1985). The musical mind: The cognitive psychology of music. Clarendon Press.

Smoliar, S. (1992). Representing listening behavior: Problems and prospects. In M. Balaban, K. Ebcioglu, & 0. Laske (Eds.), Understanding music with Al. Cambridge, MA: MIT Press.

Steinitz, P. (1991). La musica sacra tedesca. In Storia delta musica. The new Oxford history of music. Milano, Italy :Peltrinelli-Garzanti.

Terhardt, E., Stoll, G., Seewann, M. (1982). Algorithm for extraction of pitch and pitch salience from complex tonal signals. Journal of the Acoustical Society of America, 3,679-688.

Todd, P.M. (1991a). A connectionist approach to algorithmic composition. Computer Music Journal, 13(4), 27-43. Also in P.M. Todd&D.G.Loy (Eds.) (1991) Music and Connectionisin (pp. 173-189). Cambridge, MA: MIT Press.

Todd, P.M. (1991 b). Addendum to a connectionist approach to algorithmic composition. Computer Music Journal, 13(4), 27-43. Also in P.M. Todd & D.G. Loy (Eds.), Music andConnectionism (pp. 190-194). Cambridge, MA: MIT Press.

Todd, P.M., & Loy, D.G. (Eds.). (1991). Music and connectionism. Cambridge, MA: MIT Press.

Toiviainen P., & Eerola T. (2001). Method for comparative analysis of folk music based on musical feature extraction and neural networks. Proceeding of the If I International Conference on Cognitive Musicology, Jyvskyi, Finland (pp. 41-45).

Vapnik, V., Levin, E., LeCun, Y. (1994). Measuring the VC-dirnension of a learning machine. Neural Computation, 6, 851-876.

Velmans, M. (1991). Is human information processing conscious? Behavioral Brain Sci., 14,651-726.

الفصل الثالث عشر

الأنظمة الاتصالية للتنبؤ بصيد السمك

ملخص

يشرح هذا الفصل أساسات نظام دعم جديد لمصائد السمك معتمد على التقنيات الاتصالية، ومعالجة الصور الرقمية، والمنطق الغامض. الغرض من نظامنا هذا، هو زيادة نتاج مصائد السمك البحرية بدون التعرض لخطر التوازن الطبيعي للثروات السمكية. وهو يستخدم معطيات من حساسات بعيدة متنوعة، ومن سجل الأداء لقارب صيد سمك مشترك لتحسين صيد القرش Prionace Glauca – نوع من القرش البحري يعرف أيضاً بالقرش الأزرق.

مقدمة

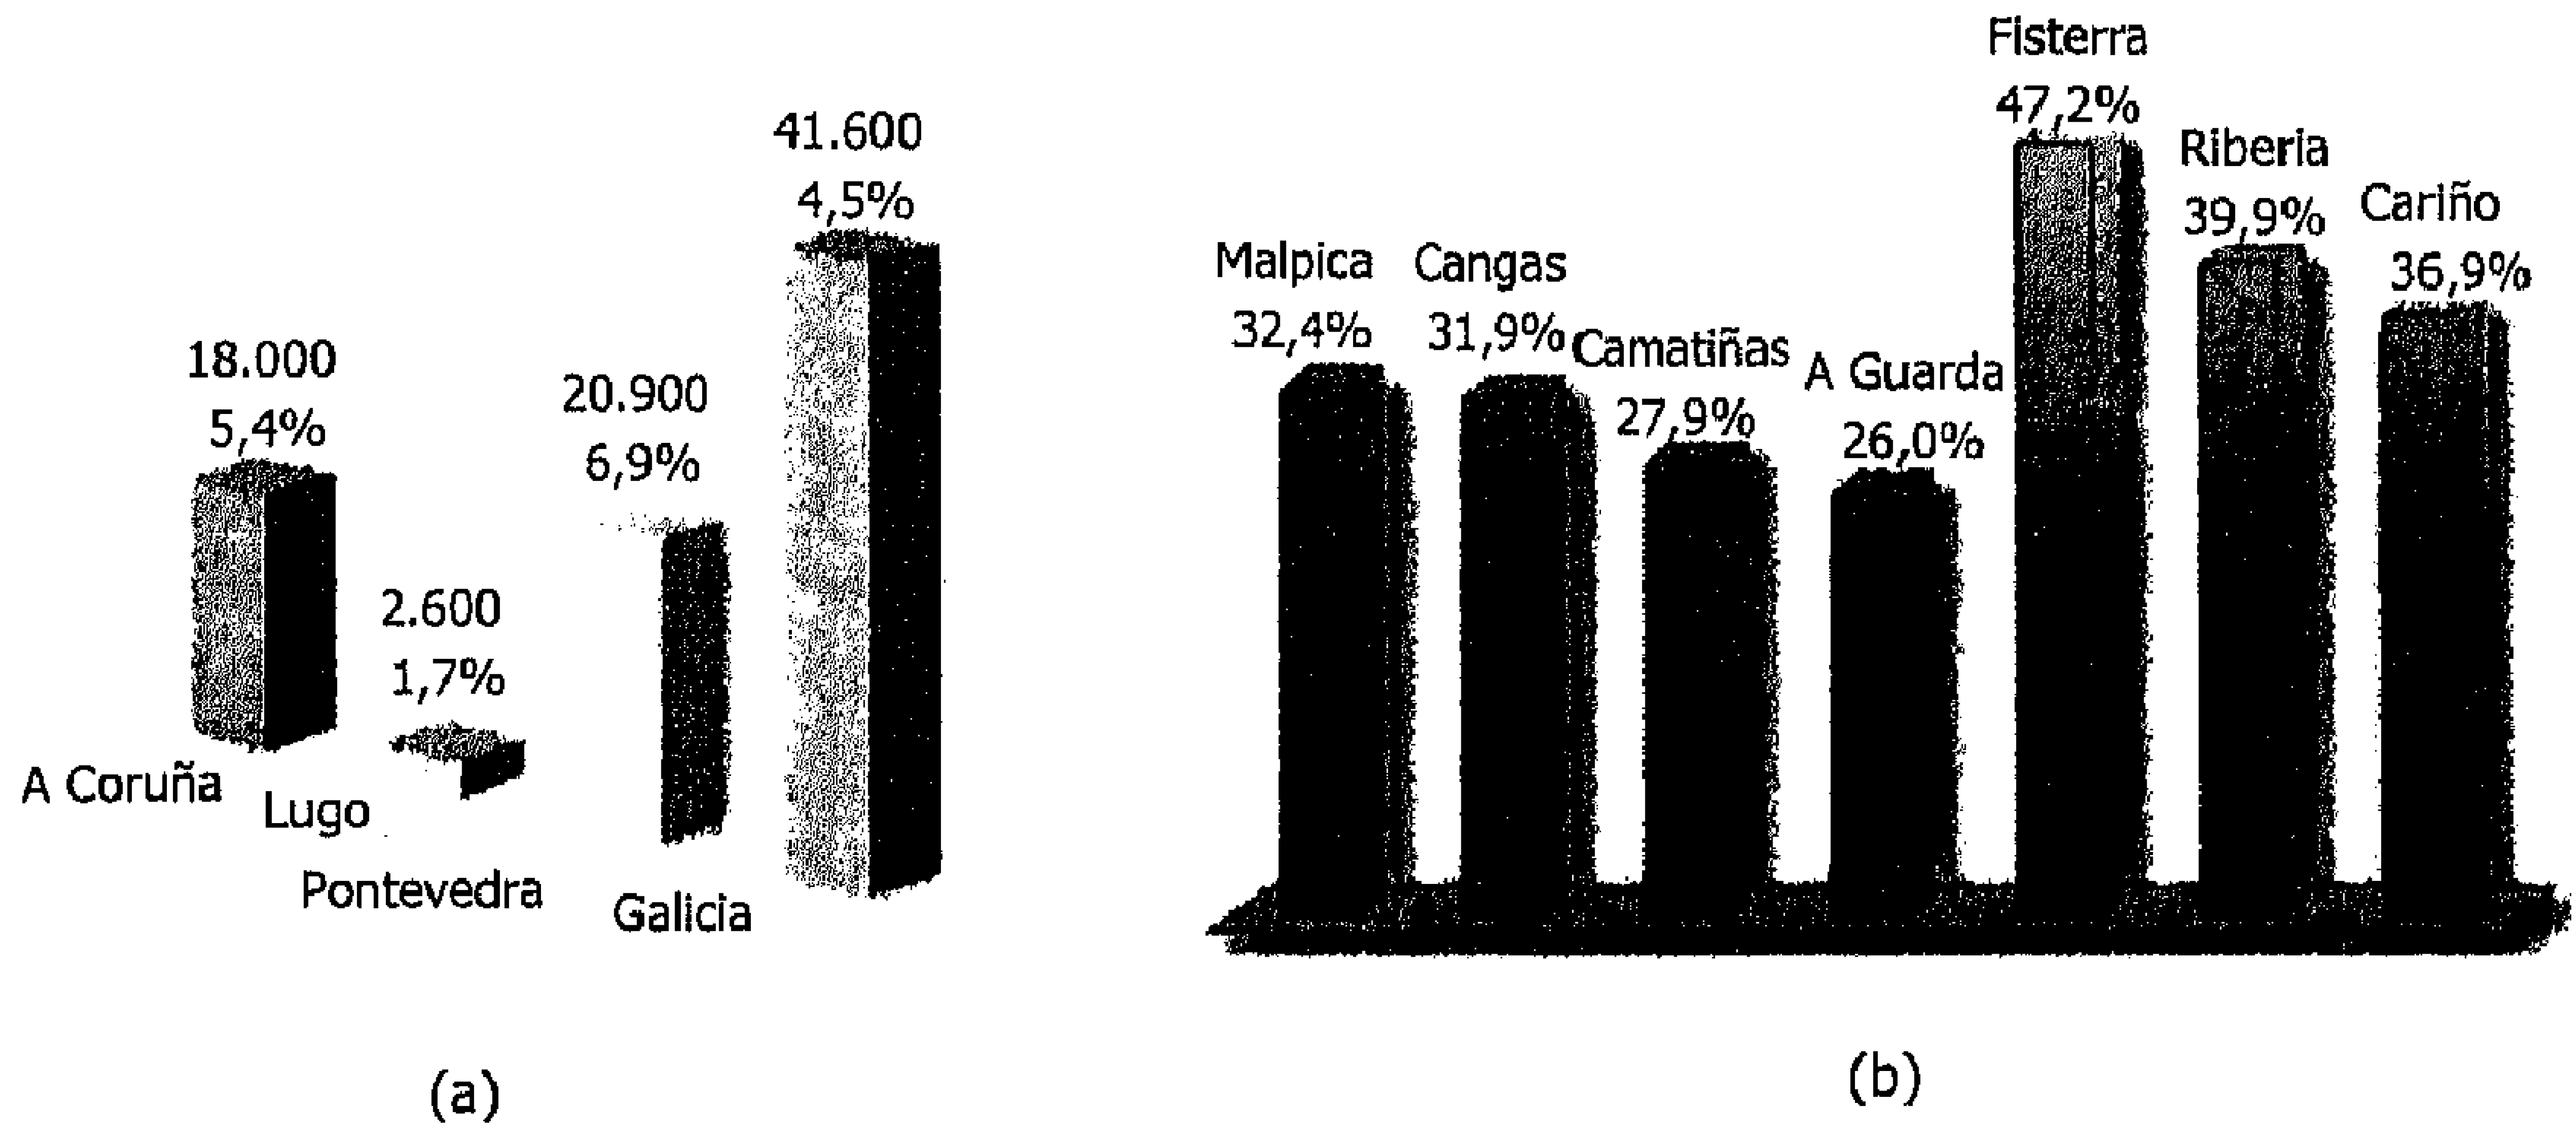
المشكلة

صيد السمك، أو استثمار وأَمْثَلَة الثروات البحرية، هو أحد القطاعات الرئيسية لمقاطعة Galicia، وأساس لعدة نشاطات صناعية وخدمات. وفقاً لجمعية صيد السمك (الشكل 1a)، فإن ما مجموعه 41600 شخص، أو 4.5% من عدد السكان العاملين بشكل مستقل متضمنين بشكل فعال في قطاع صيد السمك.

منطقياً، لا يؤثر هذا القطاع على أرض Galicia إلى نفس المدى: إذا أن المناطق مثل Fisterra، حيث 47.2% من السكان العاملين يعملون في صناعة صيد السمك، هي أعلى بكثير من معدل Galicia (الشكل 1b).

يجب أن تتضمن هذه النسبة المئوية الوظائف التي تكون قريبة جداً من قطاع صيد سمك، ويزداد عدد الوظائف المُولدّة إلى ما مجموعه 120000. وهذا يعني، بأن 12.2% من توظيف Galicia يعتمد بشكل مباشر أو غير مباشر على صناعة صيد السمك، ما يجعل منها المنطقة الأوربية التي تعتمد كثيراً على هذا النشاط.

الشكل (1) *عدد سكان Galicia العاملين في قطاع صيد السمك. a - عدد السكان بالأعداد الكلية و بالنسبة المئوية لعدد السكان العاملين من أجل كل مقاطعة (المعطيات مزودة من قبل Xunta de Galicia, 2002). b - الأهمية النسبية لقطاع صيد السمك في مناطق ساحلية متنوعة (المعطيات مزودة من قبل Xunta de Galicia, 2002).*



تبين هذه المعطيات بوضوح بأن قطاع صيد السمك في Galicia، قد نما من صناعة حرفية محلية إلى محرك لاقتصاد الحكم الذاتي. مع ذلك، فإنه القطاع المُتأثر مؤخراً بالكوارث البيئية، وسياساتُ الكوتا، والموانع البيولوجية، وتوسيع المناطق الاقتصادية الخاصة للبلدان على ضفاف الأنهار. تفرض الاتفاقيات التجارية مع بلدان أخرى استيراد السمك الأجنبي بأسعار منخفضة جداً. ومن جهة أخرى، يوجد هناك نزعة متزايدة في الأنظمة الوطنية والدولية نحو حماية أكبر للموارد الطبيعية والمحافظة عليها، وتطويرها القابل للمساندة، بحيث يحفظ المحيطات كمزود هام للغذاء للعالم بأكمله.

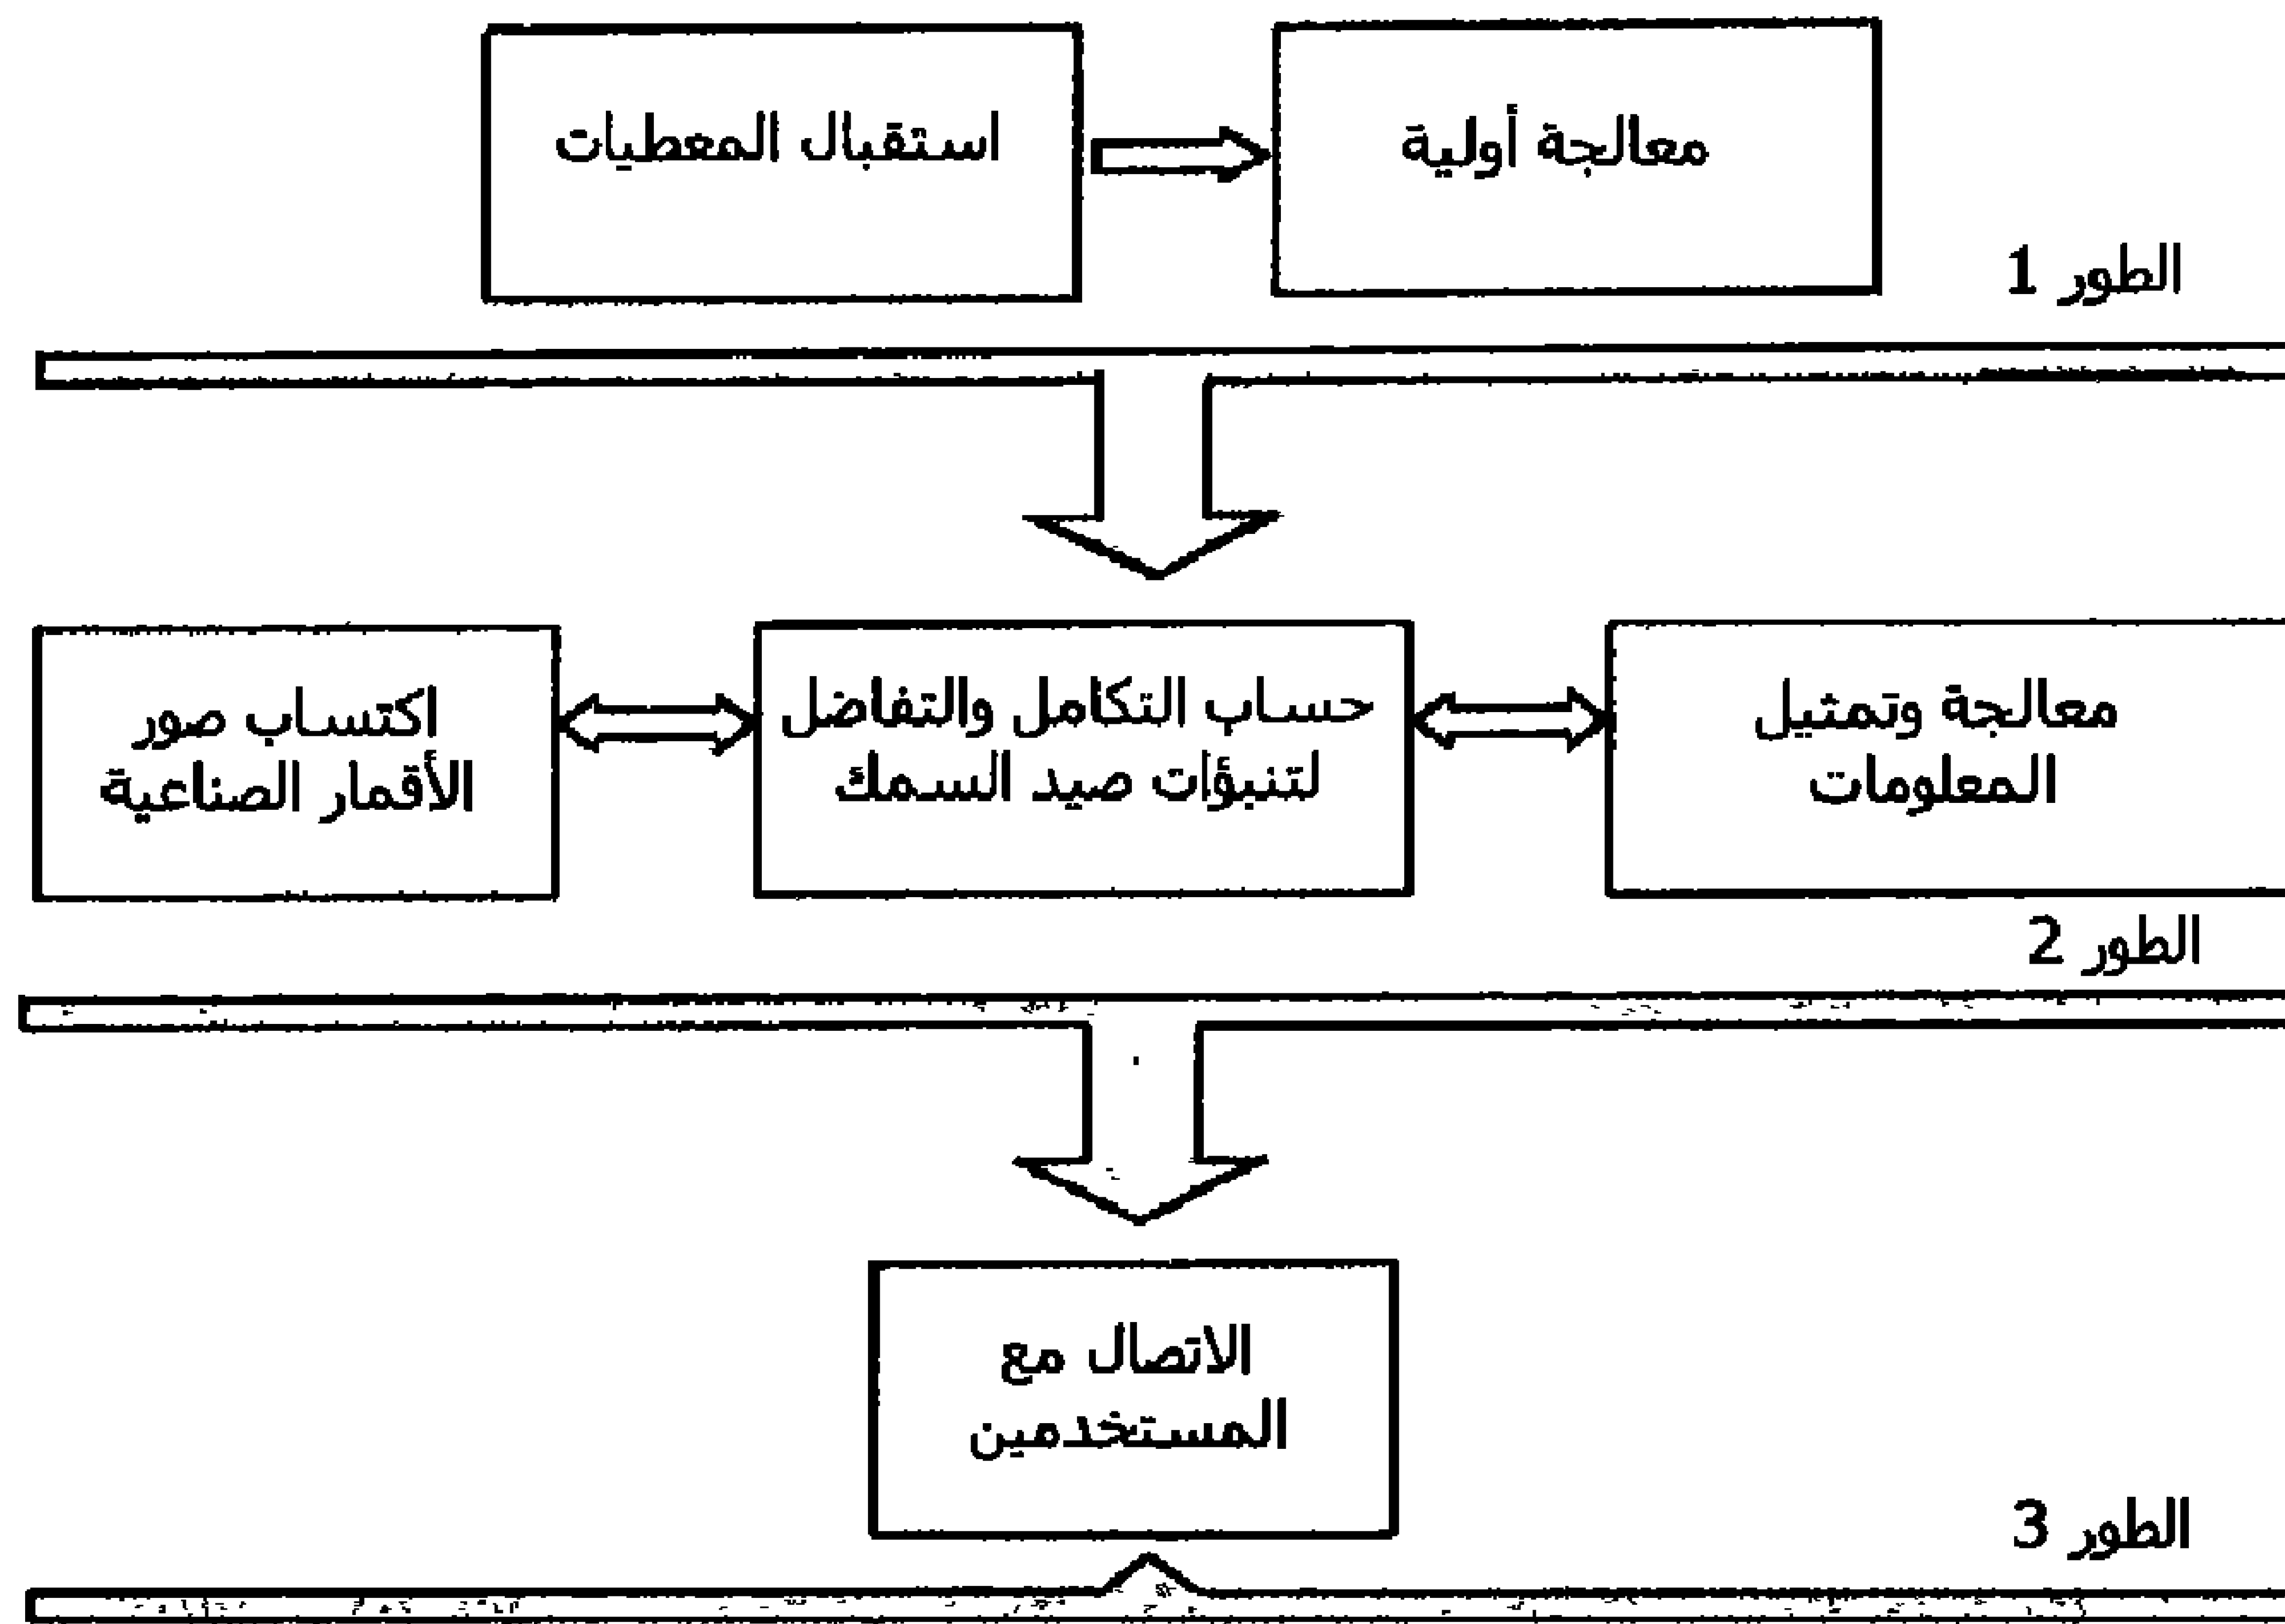
نحن نعتقد بأن أسطول صيد السمك، يمكن أن يبقى منافساً فقط، إذا استخدم التقنية الأكثر تقدماً، والكمية الأكبر من المعلومات الممكنة. في هذا السياق، فإن الحساسات البعيدة الجديدة هي أدوات مميزة، عندما تُستخدم كمصادر معلومات للظروف البيولوجية لبيئة صيد السمك. يطبق هذا العمل أنظمة اتصالية من أجل تنبؤ وأَمْثَلة الثروات المتوفرة بالاعتماد على المعلومات المُجمعة عن بعد. وهي طريقة تمكّن مصائد السمك من تقليل زمن البحث، وتوفير الوقود، وزيادة حجم الصيد ضمن حدود قانونية. بعيداً عن هذه الدوافع الاقتصادية، نريد أيضاً وضع نماذج عصبونية غامضة وعصبونية جديدة عملية، وإجراء المعالجة الرقمية للمعلومات، التي تنتج من إطلاق أقمار صناعية جديدة (القمر الصناعي Orbview 2).

الأهداف

يشرح هذا العمل قواعد نظام دعم جديد لمصائد السمك، التي تستخدم المعطيات من حساسات بعيدة، وسجل الأداء لقارب مشترك من أجل زيادة احتمالات صيد القرش البحري Prionace Glauca المعروف أيضاً بالقرش الأزرق.

يمكن أن يُوسع النظام المُطور لأي نوع بحري، يكون مُوثقاً بما فيه الكفاية. وبالتالي، فهو أداة مفيدة من أجل أَمْثَلَة وإدارة الثروات السمكية، وبشكل خاص في البيئات الجغرافية مثل Galicia، التي يعتمد اقتصادها بشكل واضح على قطاع صيد السمك. تؤمن هذه المقدمة معطيات اقتصادية، توضح أهمية القطاع الذي يُعاني من الكوارث البيئية، وفي حالات الاستثمار الجائر وغير المنطقي للموارد المتوفرة. يهدف النظام المُقدّم إلى زيادة مساعدة مستخدميه من خلال تطوير قابل للتقوية. كما هو موضح في (الشكل 2)، يتألف نظام دعم جامعة سانيتاغو دي كامبوسيتلا (Santiago de Compostela) من ثلاثة أطوار مختلفة، هدفها النهائي هو نقل تلك المنتجات، التي تكون مهيأة لكي تُرسل إلى المراكب.

الشكل (2) *المخطط العضوي لنظام الدعم لمصائد السمك المطور بمختبر الأنظمة لجامعة سانيتاغو دي كامبوسيتلا (Santiago de Compostela)*



خلال الطور 1، تُجّمع المعلومات التي تنشأ عن أقمار صناعية متنوعة، وتُخزن. يتألف النظام من مجموعة من الهوائيات، التي تستقبل المعلومات من الأقمار الصناعية (قدرة تمييز عالية ومنخفضة)،

كالقمر NOAA والقمر OrbView-2 (الصور من حساس Sea Wifs)، والقمر Meteosat. تُخزن المعطيات في نظام النسخ الاحتياطي، ويُوزع إلى حاسبات شبكة محلية، التي تتصورها وتعالجها. يمكن إيجاد وصف شامل لهذا الطور في (1994) Cotos و(1998) Trinanes.

الغرض من هذا العمل هو استخدام المعطيات، التي تنتج من الطور الأول لإنجاز الطور 2، الذي يتألف من الخطوات التالية:

- تطبيق تقنيات المعالجة الرقمية على المنتجات الأولية بغية الحصول على معطيات جديدة بمعنى بيولوجي، على سبيل المثال، مرشحات التمرير العالي التالية لكشف الجبهات الحرارية:
  - DOG (راجع Wells, 1986).
  - كل – العنقود cluster - shade (راجع Harlow, 1986).
- تصّور هذه المعلومات بشكل مستقل من المنصة المستخدمة.
- دراسة حساسية وارتباط المعطيات الأولية باستخدام.
  - تحليل المركبات الرئيسية.
  - خرائط Kohonen ذاتية التنظيم.
- حساب احتمال الحصول على صيد السمك وفقاً لبارامترات بيئية، مكتسبة من خلال الكشف عن بعد. التقنيات المطبقة هي:
  - شبكات مُدربة بخوارزمية انتشار خلفي.
  - شبكات التوابع الأساسية الشعاعية.
  - شبكات تابعية.
  - ANFIS (نظام الاستدلال العصبوني العائم).
- إدارة كافة المعلومات بفعالية وتحكم مُركز بواسطة قاعدة معطيات مناسبة مُصممة بعد النموذج E-R.

أثناء الطور 3 يتصل النظام مع المستخدمين. يمكن أن تُرسل المعلومات إلى المراكب بعدة طرق، على سبيل المثال باستخدام الشبكة العالمية عبر القمر الصناعي Inmarsat (الشكل 3). تؤمن شبكة القمر الصناعي مجالاً كاملاً من الخدمات (هاتف، معطيات، فاكس، شبكة الانترنت (الويب)، ... الخ)، وتُستخدم من أجل اتصالات الطوارئ البحرية، التي تجعل منها خدمة موجودة على العديد من المراكب.

الشكل (3) تغطية الشبكة الجغرافية الثابتة للقمر الصناعي Inmarsat.



يقدم الاتصال بالانترنت أيضاً إمكانية توصيل المعلومات عبر البريد الإلكتروني. إن البرنامج المدمج TUNAFIS 4.2 المُطوّر من قبل أعضاء آخرين من مختبر الأنظمة، يدير حسابات المستخدم ويستخلص المعلومات المُرسلة من أجل استخدامها اللاحق في واجهة الاستخدام البيانية.

أخيراً، يمكن أن تُنقل المعلومات أيضاً عبر خدمات المعطيات، المتأصلة في تقنية GSM للهاتف النقّال. عندما يكون مركب قريباً من الساحل، فإنه يستفيد كثيراً من تغطية الهاتف النقّال، ويمكن بالتالي أن يستقبل المعلومات باستخدام طرفية GSM نقّالة بسيطة مُوصولة إلى حاسب شخصي على المركب.

خلفية

مصادر المعطيات

تنشأ المعطيات، التي تُستخدم من قبل نظامنا، من حساسات بعيدة على الأقمار الصناعية. يمكن أن يُعرّف الاستشعار عن بعد كمجموعة من التقنيات، التي تسمح بالحصول على معلومات عن غرض ما، أو منطقة أو ظاهرة من خلال تحليل المعطيات المُجمعّة من جهاز، لا يكون في اتصال فيزيائي مع ذلك الغرض، أو المنطقة، أو الظاهرة (Lillesand, 1987). في حالتنا الخاصة، التي يكون فيها غرض الدراسة هو السطح البحري، والجهاز هو حساس على لوح قمر صناعي معين يمكننا تعريف الاستشعار عن بعد لجغرافية المحيطات، بأنه دراسة سطح المحيط من خلال صور الأقمار الصناعية.

يقدم الاستشعار عن بعد الفوائد الخاصة بتقنيات أخذ العينات التقليدية (معطيات مراكب مجمعة، على سبيل المثال):

- تغطية شاملة ودورية للسطح.
- الرؤية البانورامية والآنية لامتداد كبير.

- معلومات من المجالات "غير المرئية" (أشعة تحت حمراء حرارية، أشعة تحت حمراء متوسطة، الأمواج الميكروية).
- معلومات رقمية.

يستخدم هذا العمل صور من الأقمار الصناعية NOAA، وOrbView-2، وسلسة Topex-Poseidon.

يُتمّم الاستشعار عن بعد كثيراً جداً بتقنيات تقليدية أخرى من أجل معالجة المعلومات مثل أنظمة المعلومات الجغرافية GIS (Aronoff, 1991) وتُتمم المعطيات التي تنشأ عن معالجة صور الأقمار الصناعية بمعطيات المجال الواردة من مركب صيد السمك المشترك. وتشمل المعلومات على إحداثيات جغرافية في بداية ونهاية خط الطول، التي هي تقنية صيد السمك المطبقة، ومن صيد لكل نوع مُجمّع على أساس يومي خلال السنوات 1998 و1999.

الشبكات العصبونية

تتقدم الشبكات العصبونية كثيراً منذ ظهور المنشورات الأولى من قبل الباحثين McCulloch وPits: حالياً، هما مؤسسا حقل جديد، متجذرٍ بعمق في علم الأعصاب، وعلم النفس، والفيزياء، والهندسة. قام العديد من الأعمال قبلٍ عملنا هذا بوصف هذه الشبكات كطريقة ملائمة للحصول على نتائج موثوقة في تحليل بارامترات صيد السمك من خلال معطيات الكشف عن بعد. وفيما يلي الأمثلة المشهورة:

- يتنبأ Komatsu, Aoki, Mitani, and Ishii (1994) صيد السردين الياباني بالشبكات العصبونية، وقاموا بتحليل الأوزان المشبكية بغية تحديد ما هو الأكثر أهمية العامل الفيزيائي أم البيولوجي. لم تعطِ النوايا السابقة نتائج مرضية بالنماذج الارتدادية بسبب الارتباط بين متغيرات الدخل.
- يتنبأ Aurelle, Lek, Giraudel, and Berrebi (1999) معطيات صيد السمك بشبكة Perceptron ذات ثلاثة طبقات وعصبونين في الطبقة الخفية مدربة بخوارزمية الانتشار الخلفي للخطأ.
- يستخدم Dreyfus - Leon (1999) الشبكات العصبونية للتنبؤ سلوك صياد السمك.
- يتنبأ Aussem & Hill (2000) وجود طحلب أخضر ضار (Caulerpa taxifolia) بشبكة Perceptron متعددة الطبقات وتدريب مُراقب.
- يتنبأ Mass, Boulanger, and Thiria (2000) البارامترات البيئية باستخدام سلسلة زمنية، توافق ظاهرة "النو" (EL Niňo)

- يتنبأ Brosse, Guegan, Toureng, and Lek (1999) وفرة السمك في البحيرات بالشبكات العصبونية، وهم يقارنون الشبكات العصبونية ذات الانحدار الخطي المتعدد مع تحليل المركبات الرئيسية، ويثبت بأن الشبكات العصبونية تعطي التنبؤات الأكثر دقةً.

يمكن أن تُعرّف أي شبكة عصبونية صنعية (ANN)، بأنها آلة، تُصمم لنمذجة الأسلوب الذي ينفذ فيه الدماغ البشري مهمة أو وظيفة ما. تُنفّذ الشبكة العصبونية عادةً بمكونات الكترونية، أو تُحاكى من قبل برنامج ناعم، وتستخدم اتصالات بينية هائلة بين عناصر المعالجة البسيطة تدعى بالعصبونات.

يمكن أن تُعرف أيضاً أي شبكة عصبونية صنعية كمعالج متوازي موزع بشكل ضخم، عنده القدرة الطبيعية لتخزين المعرفة، وجعلها متوفرة للاستخدام المستقبلي، وهي تشبه الدماغ البشري في سمتين:

- تُكتسب المعرفة من قبل الشبكة عن طريق عملية تعلّم.
- تُستخدم الاتصالات بين العصبونات - المعرفة كأوزان مشبكية - لتخزين المعرفة.

إن البنية الاتصالية بدرجة عالية للشبكات، وقدرتها على المعالجة المتوازية، وقدرة تعلّمها، يجعل التناظر المشروح سابقاً (Haykin, 1999) ممكناً.

تُنفّذ عملية التعلّم بقاعدة تعلّم أو خوارزمية، تهدف نحو غرض معين بتعديل الأوزان المشبكية في أسلوب منتظم. يمكن أن تكون هذه العملية مُراقبة أو غير مُراقبة. يتم التحكم بعملية التعلم المُراقب من قبل المصمم، الذي يقرر متى ينتهي التدريب وفقاً للخطأ الحاصل بين خرج الشبكة وخرج نمط التدريب. ويحدث التعلم غير المراقب عبر تطبيق المعطيات إلى المدخلات بدون استخدام المخرجات كمؤشرات خطأ.

تكمن القوة الحسابية للشبكات العصبونية في كلٍّ من الكمية الكبيرة من الاتصالات البينية بين عناصر المعالجة خاصتها، وفي قدرتها على التعلّم وعلى التعميم - بكونه قدرة الشبكات العصبونية على إنتاج خرج معقول للمدخلات، التي لم تكن موجودة أثناء عملية التدريب. بفضل هذه القدرات، يمكن أن تحل الشبكات العصبونية مسائل معقدة، التي لا يمكن معالجتها حالياً. بالرغم من أنها لا تستطيع فعل ذلك بشكل منفصل، ويلزم لأن يُدمج في أنظمة أخرى.

بالرغم من هذا التقييد، فإن استخدام ANN يقدم الميزات التالية:

- **اللاخطية**: بما أن العصبونات هي عناصر لاخطية، فإن الشبكات العصبونية المصنوعة من عصبونات متصلة بينياً هي أيضاً لا خطية. وهذه الميزة خاصة في أنها موزعة على كامل الشبكة.

- **الائتلافات بين الدخل والخرج**: إن الشبكات قادرة على تعلم الائتلافات المعقدة بين الدخل والخرج بواسطة عملية تدريب، قد تكون إما مُراقبة أو غير مُراقبة.
- **التكيّفية**: القدرة على تكيّف الأوزان المشبكية للشبكة للتغيرات في البيئة. أي شبكة مُدربة للعمل في بيئة محددة يمكن بسهولة إعادة تدريبها، عندما تتغير ظروف تلك البيئة.
- **تحمّل الخطأ**: أي شبكة عصبونية تتحمل الخطأ، لأن المعرفة مُقسمة على كافة الأوزان.
- **التناظر البيولوجي العصبي**: إن تصميم أي شبكة عصبونية مدفوع بالتناظر مع الدفاع البشري، الذي يوضح بأن المعالجة المتوازية ممكنة وسريعة وقوية.

لقد اخترنا الشبكات العصبونية المُدربة بخوارزميات مُراقبة، لأنه لا يوجد تابع توافقية محدد مسبقاً بين معطيات دخلها وخرجها. طبق العديد من المؤلفين بنجاح شبكات عصبونية في مجال الاستشعار عن بعد، كما يلاحظ في Trinanos (1994)، Torres (200) وBenediktsson (1990).

الشبكات التابعية

بدأت تلك الامتدادات لنموذج الشبكة العصبونية بالظهور منذ منصف الثمانيات (1980s). بعض الأمثلة للامتدادات هي الشبكات عالية المرتبة، والشبكات العصبونية الاحتمالية (Specht, 1990)، والشبكات العصبونية المعتمدة على "الموجات الصغيرة" "Wavelets". هذه النماذج الجديدة، على أية حال، ما تزال تعمل كصناديق سوداء، بحيث لا تدرس البنية التابعية والخصائص للجسم الذي تقوم بنمذجته. الخاصية الهامة للشبكات التابعية هي إمكانية معالجة القيود التابعية، التي تُحدد من قبل الخصائص التي قد تكون معلومة للنموذج. ستؤدي هذه القيود إلى طبولوجية شبكة معينة، وبالتالي إلى نظام من المعادلات التابعية. قُدّمت المعادلات التابعية من قبل Castillo and Gutiérrez (1998) كامتداد للشبكات العصبونية بأسلوب بسيط ولكن صارم، يمكن فيه تعريف الشبكة التابعية كشبكة عصبونية، تُبدل فيها أوزان العصبونات بمجموعة من التوابع. وبعض فوائدها (Castillo, Cobo, Gutiérrez, & Pruneda, 1999) هي التالية:

1. يمكن للشبكات التابعية إعادة إنتاج بعض الخصائص الفيزيائية، التي تقود بأسلوب طبيعي باتجاه الشبكة الموافقة، شرط أن تستخدم تعبيراً مع تعبير فيزيائي في أساس التوابع. في حالتنا، لا يمكن أن تُستغل هذه الميزة لأننا، لا نتخلص من تلك المعلومات.
2. يمكن الحصول على تقدير بارامترات الشبكة بحل مجموعة المعادلات الخطية، التي تشكل حلاً سريعاً ووحيداً، والنهاية الصغرى العامة لتابع الخطأ.

تم تطبيق الشبكات التابعية بنجاح على مسائل متعلقة بالتشخيصات الطبية، وبتوزيعات Bayes. يمكن إيجاد وصف تلك المسائل وحلها بواسطة الشبكات التابعية والصيغة الكاملة المناسبة للمعادلات والشبكات التابعية في الكتاب المُعّد من قبل الباحث .Castillo et al (1999).

تشمل أي شبكة تابعية على العناصر التالية:

1. **طبقة دخل وحدات التخزين.** تحتوي هذه الطبقة على معطيات الدخل.
2. **طبقة خرج وحدات التخزين.** تحتوي هذه الطبقة على معطيات الخرج.
3. **طبقة واحدة أو عدة طبقات من وحدات المعالجة.** تقيّم هذه الوحدات مجموعة من قيم الدخل الواردة من الطبقة السابقة (طبقة متوسطة أو طبقة الدخل)، وتُحسب القيم التي ستُعتبر للطبقة التالية. يملك كل عصبون تابعه العصبوني الخاص، بحيث يمكن أن يمتلك عدة متغيرات أو مدخلات: وهذا يساعد على إدخال جزءاً من النموذج الرياضي في كل وحدة معالجة، ما يساعد في شرح مسألتنا.
4. **لا شيء، أو طبقة واحدة، أو عدة طبقات من وحدات التخزين المتوسطة:** تحتوي هذه الطبقات على وحدات، تخزن المعلومات المتوسطة المنتجة بالوحدات العصبونية، بحيث تسمح لها بإجبار التزامن لمخرجات وحدات المعالجة.
5. **مجموعة من أدوات الربط الموجهة.** تصل وحدات الدخل أو الطبقات المتوسطة مع الوحدات العصبونية، والوحدات العصبونية مع الوحدات المتوسطة أو مع وحدة الخرج.

ANFIS

يسهل استخدام الشبكات العصبونية التعلم، وتقليل تابع الخطأ ليصبح أصغرياً، واستخدام الحساب المتوازي. تعطي هذه التقنيات – على أية حال – نتائج قاصرة في تمثيل المعرفة، واستخلاص القواعد اللغوية. ففي شبكة Perceptron متعددة الطبقات – على سبيل المثال – تكون المعرفة موزعة في مجموعة أوزان، من الصعب تفسيرها أو تحويلها إلى قواعد. أما المنطق العائم – فعلى النقيض من ذلك – يترجم الحدود الرمزية للقواعد إلى متغيرات، تكون مقبولة بدون مشاكل من قبل النظام.

الغرض من الأنظمة العائمة العصبونية هو دمج فوائد كلا التقنيتين. إلى هذا التأثير، تُمثل قواعد النظام كتعابير عائمة، ويُدرّب النظام باستخدام مخططات تعلم الشبكات العصبونية. تسمح الأنظمة العائمة العصبونية باندماج المعطيات اللغوية والعددية، واستخلاص القواعد من المعطيات العددية.

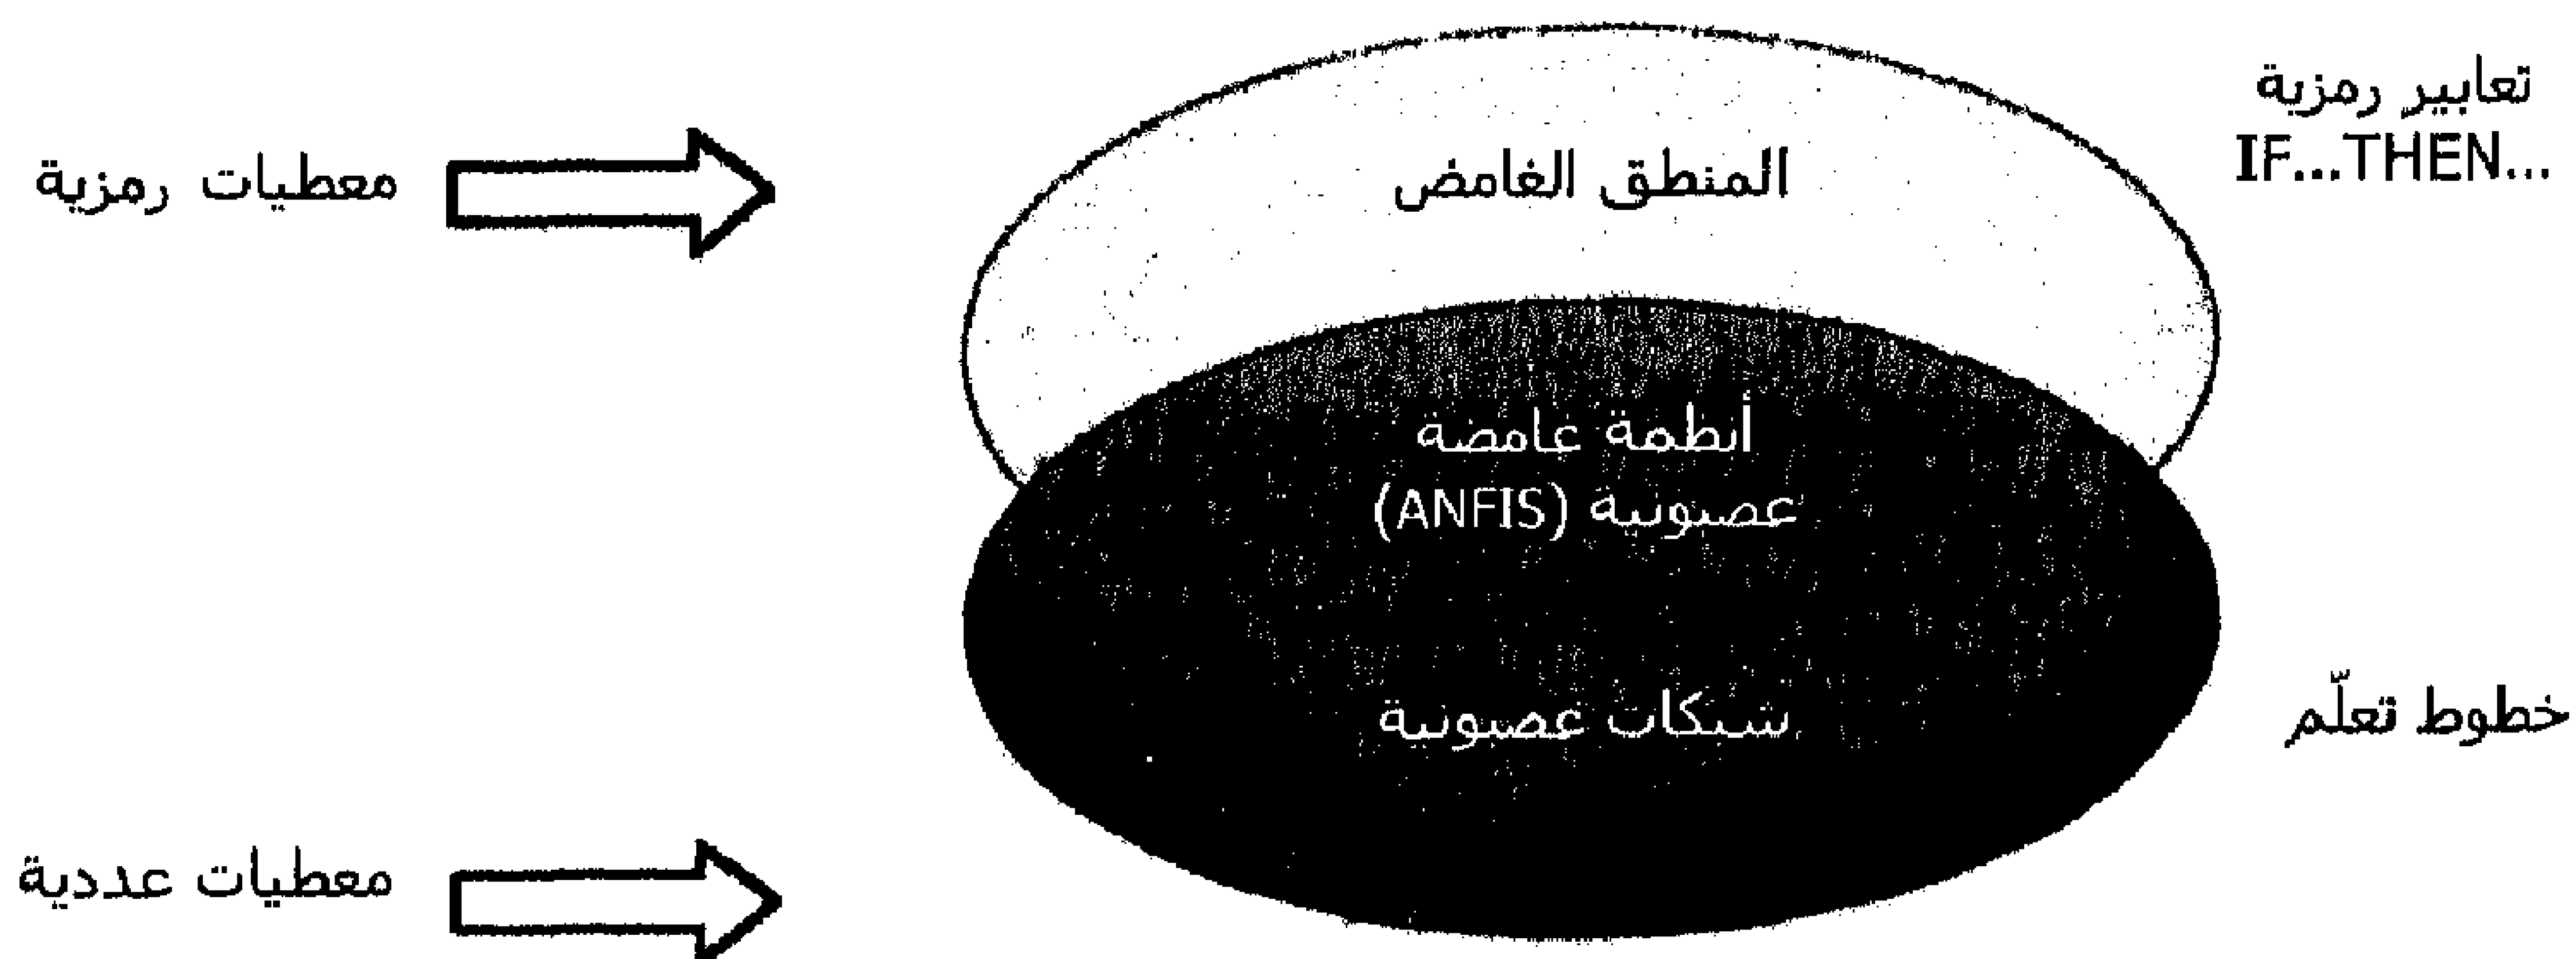
يمكن تقسيم الأنظمة العائمة العصبونية إلى مجموعتين رئيسيتين:

1. أنظمة استدلال غامضة عصبونية.
2. شبكات عصبونية غامضة.

أساس أنظمة الاستدلال الغامضة العصبونية هو دمج مفاهيم مثل التعلم والتوازي في أنظمة الاستدلال الغامضة. تُنفذ أنظمة الاستدلال الغامضة العصبونية استدلالاً غامضاً (Jang, 1993; Berenji, 1992) بضبط بارامترات القواعد الداخلية بخوارزميات تعلم شبكات عصبونية. يمكن أن تُنفذ كل قاعدة بواسطة شبكة عصبونية، ولكن من الممكن أيضاً تطبيق بنية هندسية ANFIS كما هو الحال في عملنا.

تتضمن الشبكات العصبونية العائمة مكونين في منظومة فرعية واحدة هما: الشبكة العصبونية والنظام الغامض. ستتضمن أي توليفة ممكنة لكلا المكونين في استبدال المجموع المُثقل لعصبون بعملية غامضة، أو حتى بكتلة خارجية، تترجم المعلومات اللغوية إلى دخل الشبكة الموافق.

الشكل (4) *تدمج الأنظمة الغامضة العصبونية المنطق الغامض والشبكات العصبونية.*



نتائج التقنيات المطبقة

تدريب شبكات الانتشار الخلفي والتابع الأساسي الشعاعي

تتلخص المشكلة في تحديد الشروط الأمثلية من أجل كمية عظمى من صيد القرش Prionance Glauca. بعد دراسة معتمدة على المكونات الرئيسية وشبكات Kohonen (SOM)، قررنا بأنه يمكن أن تُخفض مجموعة معطيات الدخل المؤلفة من خمس بارامترات إلى أربعة بارامترات (درجة حرارة، تبريد – تدفئة الماء، اليخضور (كلوروفيل)، وقياس الارتفاعات). نُبذ

المتغير الخامس، لأنه لا يزيد معلومات جديدة. وهكذا، لا يكون لدينا فقط معلومات من سجل أداء صيد السمك، بل وأيضاً مجموعة من الأنماط، التي يمكن أن تستخدم لتدريب الأنظمة الاتصالية. ما إن تُدرب الشبكات العصبونية بشكلٍ مرضٍ حتى تصبح أدوات توقع ناجحة جداً (Komatsu et al., 1994، Aurelle et al. 1999، Drefus-Leon, 1999، Aussem, 2000، Brosse et al. 1999، Mass et. al., 2000).

إن شبكة Perceptron متعددة الطبقات (MLP) المُدربة بانتشار خلفي للخطأ، وشبكة التابع الأساسي الشعاعي (RBF) هما نوعان مشهوران من الشبكات العصبونية. يحلل القسم القادم سلوكها في مجموعة تدريب خاصة.

شبكات الانتشار الخلفي

خلقنّا شبكة Perceptron متعددة الطبقات بأربعة متغيرات دخل (درجة حرارة سطح البحر (SST)، تبريد – تدفئة، تركيز اليخضور، وقياس الارتفاعات)، ومتغير خرج واحد (صيد نوع من القرش يدعى Quenlla)، ودرسنا سلوكها وفقاً للمعايير التالية:

- عدد الواحدات في الطبقة الخفية.
- عدد الأنماط في مجموعة التدريب ومجموعة الاختبار.
- تغيير بارامترات خوارزمية التعلم.

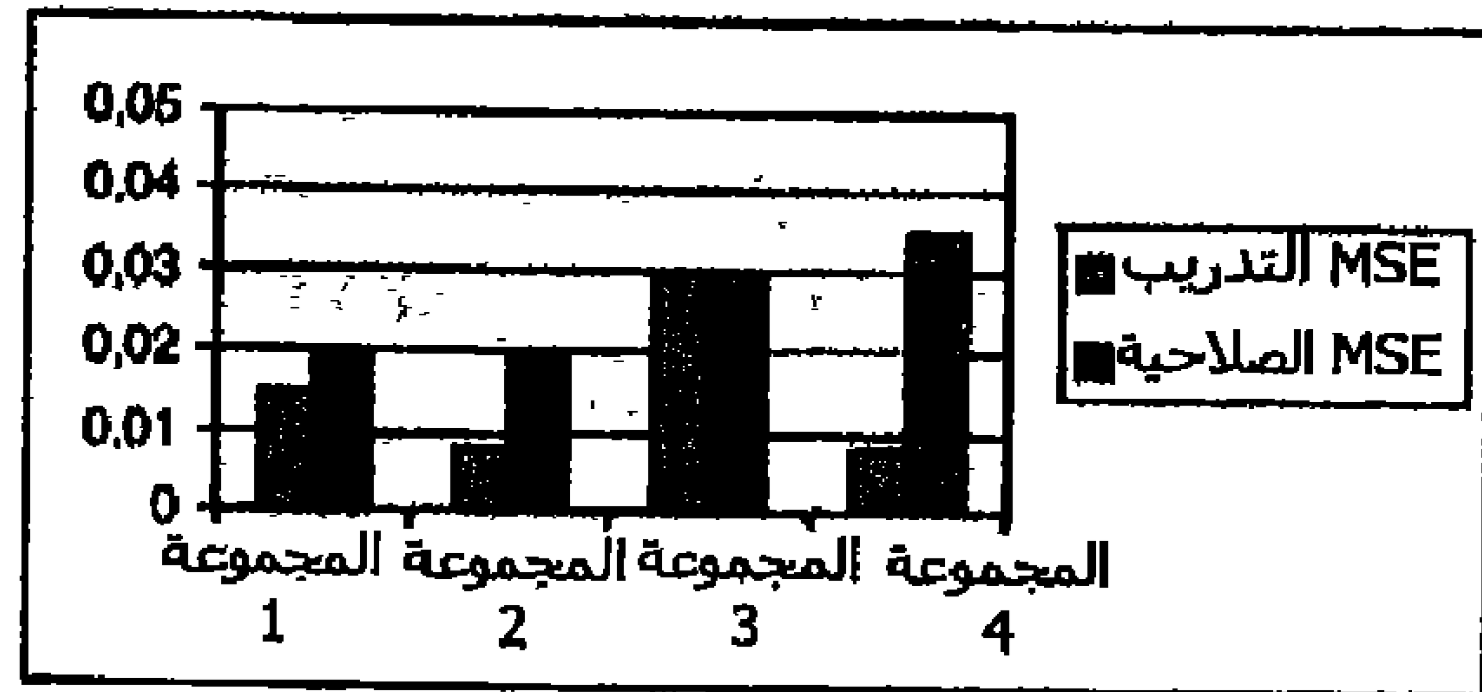
كان هدفنا إيجاد الشبكة الممكنة الأبسط، التي تسمح لنا بتحديد الشروط التي بموجبها يمكن أن يكون صيد الوحدة المشحونة (المركب) أعظمياً.

عندما دُرّبت الشبكة، لاحظنا أن عدد عصبونات الطبقة الخفية يؤثر بالكاد على الخطأ المُقدّم من قبل الشبكة. هناك اختلافات أولية صغيرة قد يكون سببها التهيئة العشوائية لأوزان الشبكة. في كافة الحالات، تبقى MSE لمجموعة التدريب قريبةً جداً من 0.01، بينما يبقى خطأ مجموعة الصلاحية بعض الشيء تحت 0.02. هذه النتائج جعلتنا نختار الشبكة، التي يكون لها فقط عصبونان في طبقتها الخفية، وتسمح لنا بتفسير معلومات مجموعة الأوزان بسهولة أكثر.

نرصد سلوك الشبكة بعد تغيير عدد أنماط مجموعة التدريب ومجموعة الصلاحية. تستخدم أربعة مجموعات تدريب وصلاحية مختلفة لتدريب شبكة بعصبونين في الطبقة الخفية. تمتلك كل مجموعة الأنماط المبينة في (الجدول 1).

الجدول (1) مجموعات التدريب المُختبرة وتمثيل الأخطاء المكتسبة.

المجموعة	عدد أنماط التدريب	عدد أنماط الصلاحية
1	57	38
2	72	23
3	48	47
4	80	15



تُقدم نتائج التدريب وفقاً لمجموعة التدريب/الصلاحية المطبقة مع بارامترات مؤشرة. يمكننا ملاحظة، أن المجموعة 3 تعطي أسوأ النتائج: نتيجةً لعدد الأنماط المنخفض الذي يشكل مجموعة التدريب، يصل MSE لتلك الأنماط إلى المستوي 0.03. تزيد المجموعة 4 خطأ الصلاحية بسبب فقدان الشبكة لقدرة التعلم. نحاول تصميم شبكة لا يكون لها فقط خطأ أصغر أثناء عملية التعلم، وإنما تكون أيضاً قادرة على توقع الخرج بالدقة العظمى الممكنة. ولا تعطينا هذه المجموعة النتائج المرغوبة.

في المجموعة 1 و2 يكون خطأ الصلاحية متماثلاً تقريباً، وبالتالي فهو ليس معياراً صالحاً، ولكن يوجد اختلاف صغير في خطأ التدريب، الذي يكون أقل من أجل المجموعة 2.

بدراسة النتائج في جدول الخطأ يمكننا أن نستنتج، بأن سرعة التدريب تعتمد على القيمة 2 في المجموعة 2، إذا كانت $\eta = 1.0$ ، يصل الخطأ لقيمة ثابتة بـــ 4000 دورة تدريب. ولكن إذا كان $\eta = 2.0$، فإن الخطأ الثابت يصل تقريباً بعد 1.000 دورة. وتتفق النتائج – بالتالي – مع الإصدار النظري لطريقة الانتشار الخلفي.

اختيار الشبكة

أخيراً، يجب اختيار النتيجة الأكثر إقناعاً. على أساس الاستنتاجات السابقة، نختار شبكة بالمواصفات التالية.

1. عصبونات في الطبقة الخفية. بما أن عدد العصبونات في الطبقة الخفية لا يؤثر على النتيجة، فقد اخترنا العدد وفقاً للتفسير اللاحق لمجموعة الأوزان.
2. تدريب المجموعة 2، التي لها خطأ التدريب والصلاحية الأكثر قبولاً، ولها توزيع متوازٍ للأنماط المختلفة. من الآن فصاعداً سنستخدم هذه المجموعة لتدريب الأنظمة الاتصالية.
3. تعطي بارامترات خوارزمية الانتشار الخلفي تدريباً سريعاً تقريباً، ولكن لن تؤثر على النتيجة.

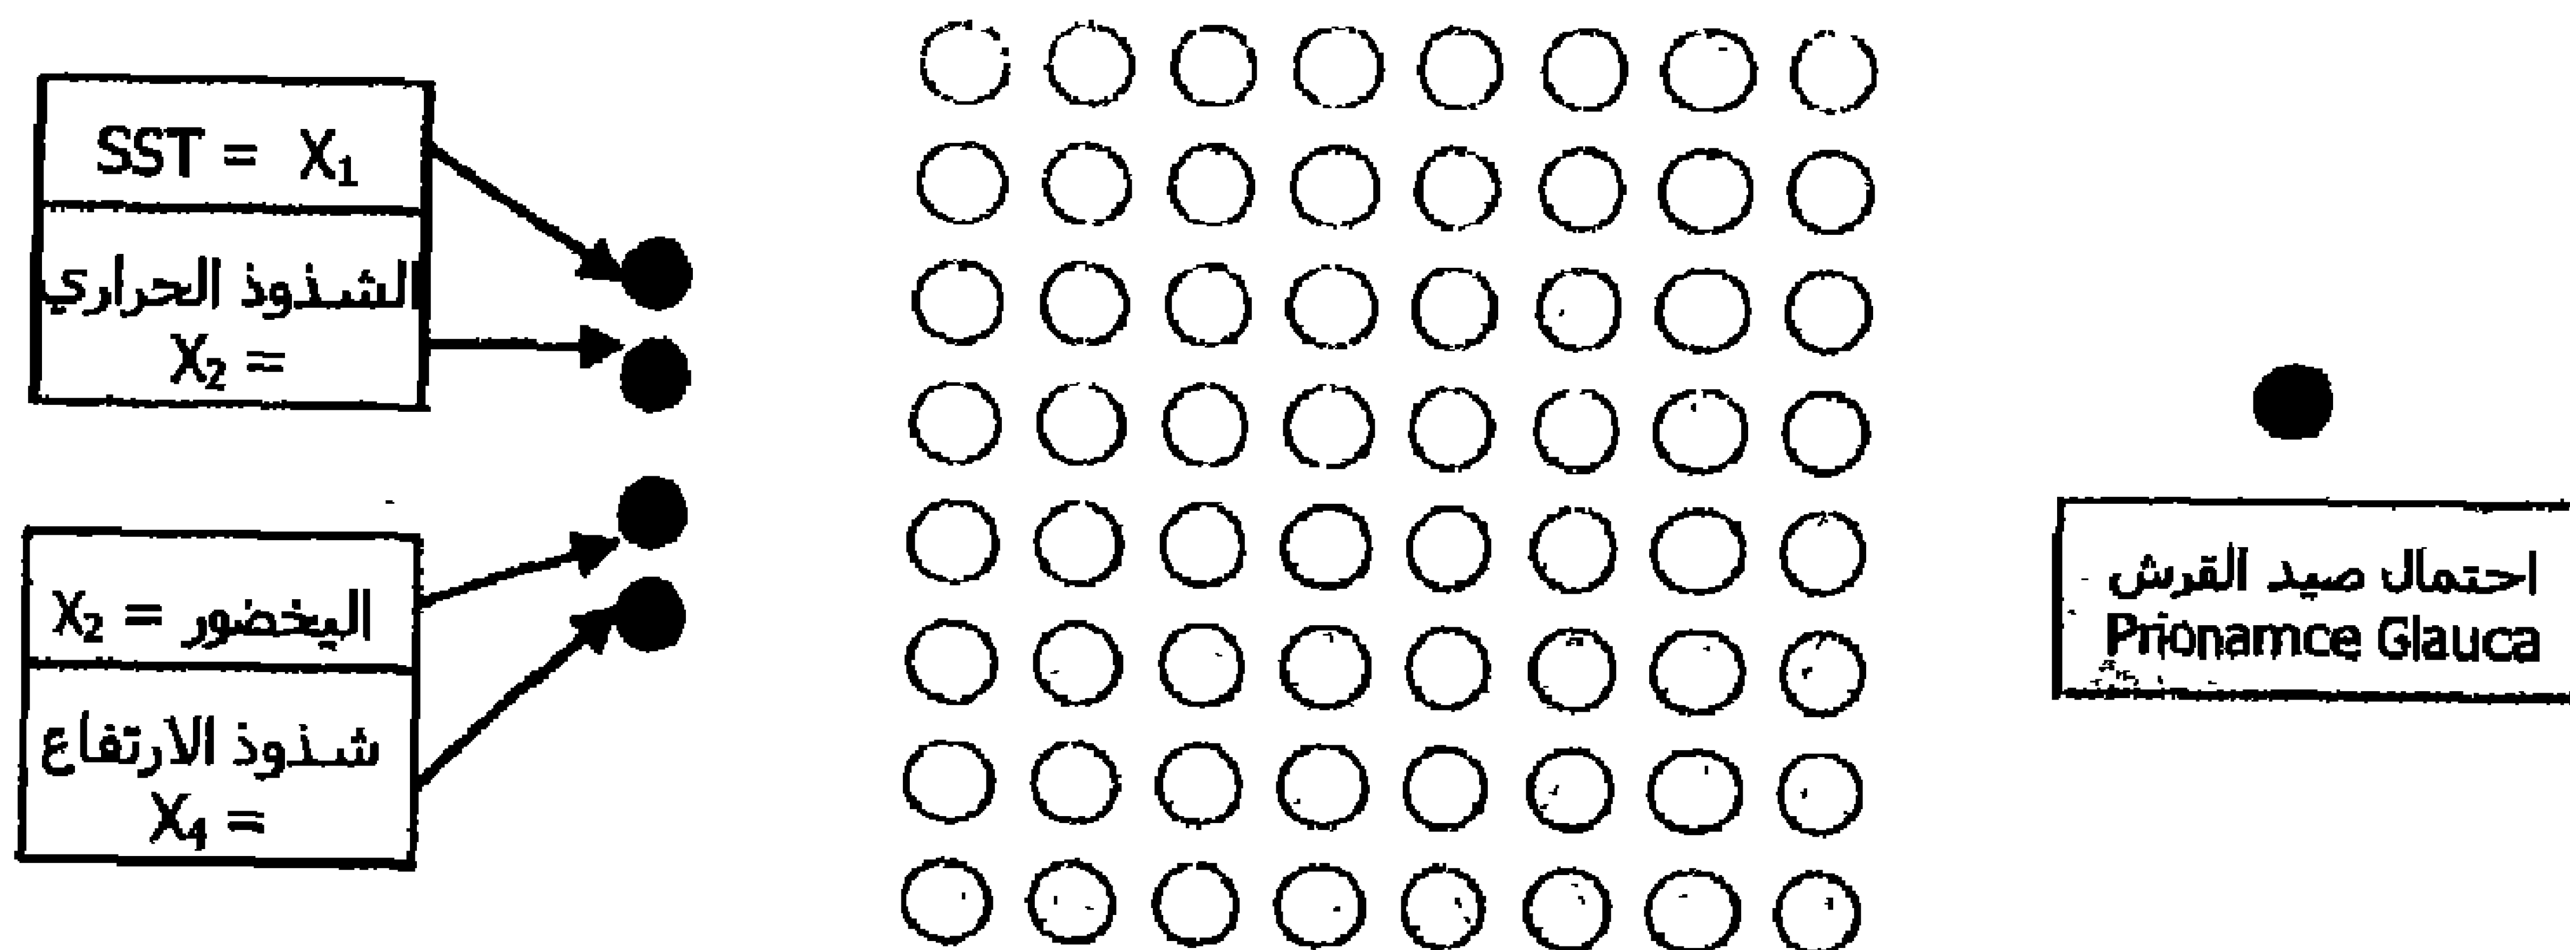
شبكات RBF

تُقارن النتائج المكتسبة مع طرق التهيئة التالية:

1. اختيار المراكز المتوسطة بالاعتماد على أنماط التدريب.
2. اختيار المراكز المتوسطة بشبكات Kohonen.

استخدمت الشبكات، التي طُبقّت لتنفيذ تلك الاختبارات، توابع غاوس كتوابع تفعيلٍ عصبونات الطبقة الخفية. رُكّبت الطبقة في بنية ثنائية الاتجاه من 8 × 8 عصبون تم وصلها جميعاً إلى أربعة مداخل وخرج واحد فقط (الشكل 5).

الشكل (5) *شبكة RBF المُصممة.*



من أجل تحقيق التماسك، اخترنا نفس الاتجاهات للطبقة الخفية كما في الدراسة السابقة المعتمدة على خرائط التنظيم الذاتي (SOM). تستخدم إحدى طرق التهيئة المختارة شبكات Kohonen لاختيار قيم المراكز المتوسطة لتوابع غاوس.

وفيما يلي النتائج من أجل نوعي التهيئة:

الإجراء 1 (اختيار المراكز المتوسطة بالاعتماد على أنماط التدريب)

يختار هذا الإجراء المراكز t_j لأنماط التدريب في المسلك، وتعينهم إلى الروابط بين طبقات الدخل والطبقات الخفية (الشكل 6).

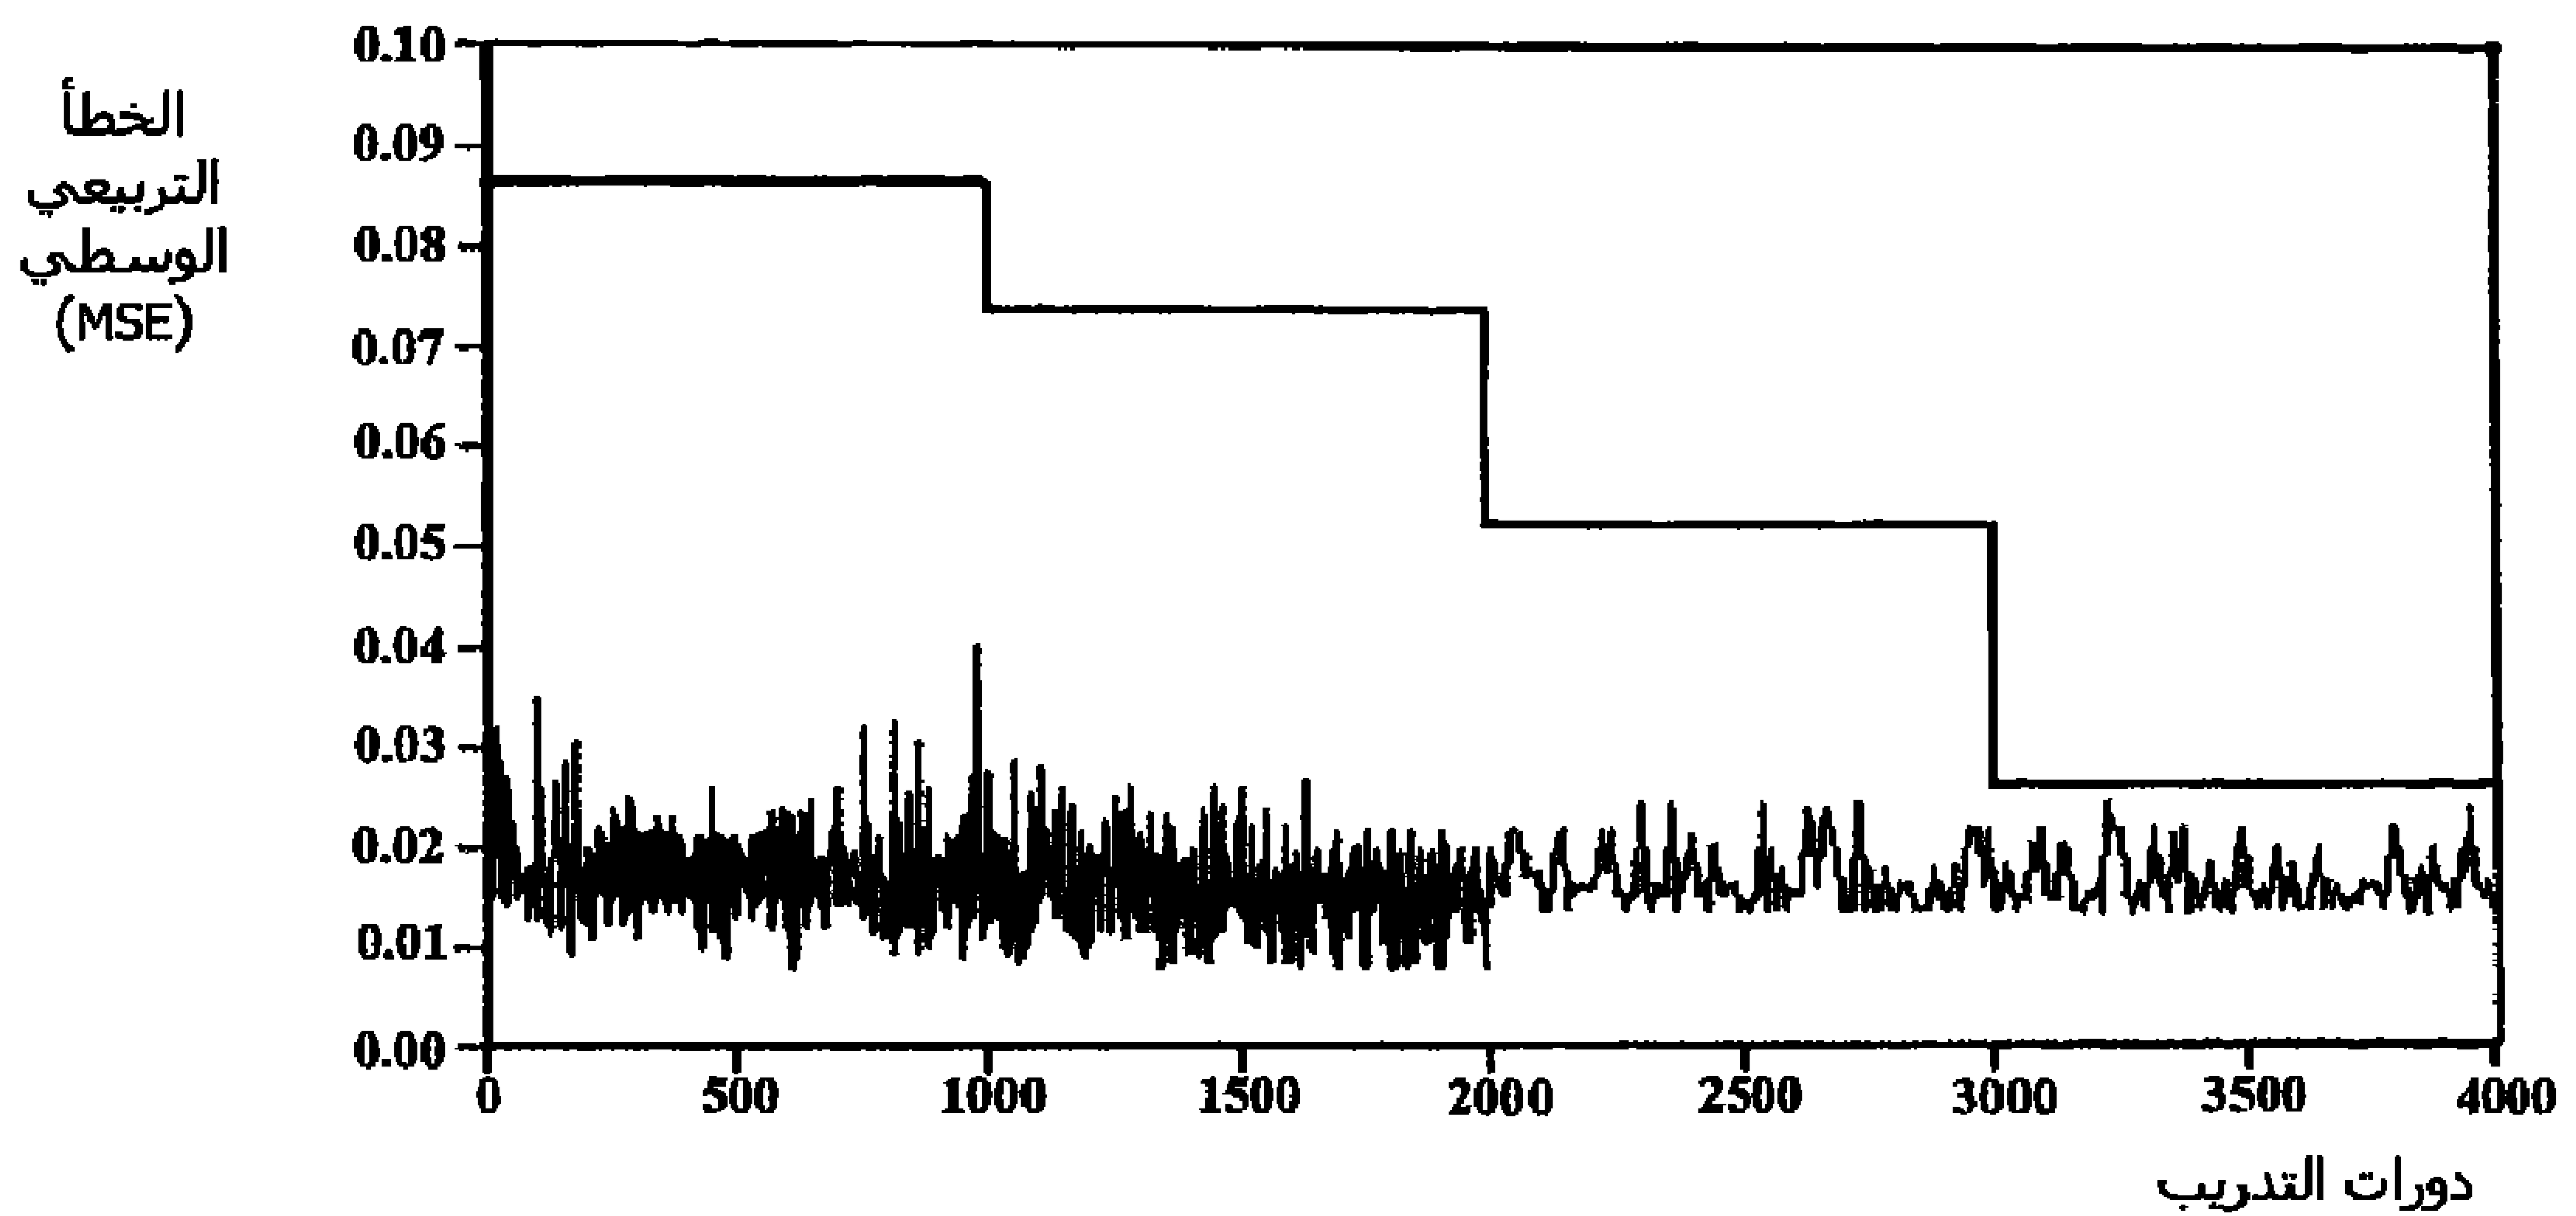
الإجراء 2 (شبكات Kohonen)

في طريقة التنظيم الذاتي لخرائط Kohonen، تُوّلد المراكز المناسبة على أساس أنماط التعلم، a – في سرعة التعلّم: لا تغير القيمة 0 شعاع المركز المتوسط، بينما تبدل القيمة 1 الشعاع المختار

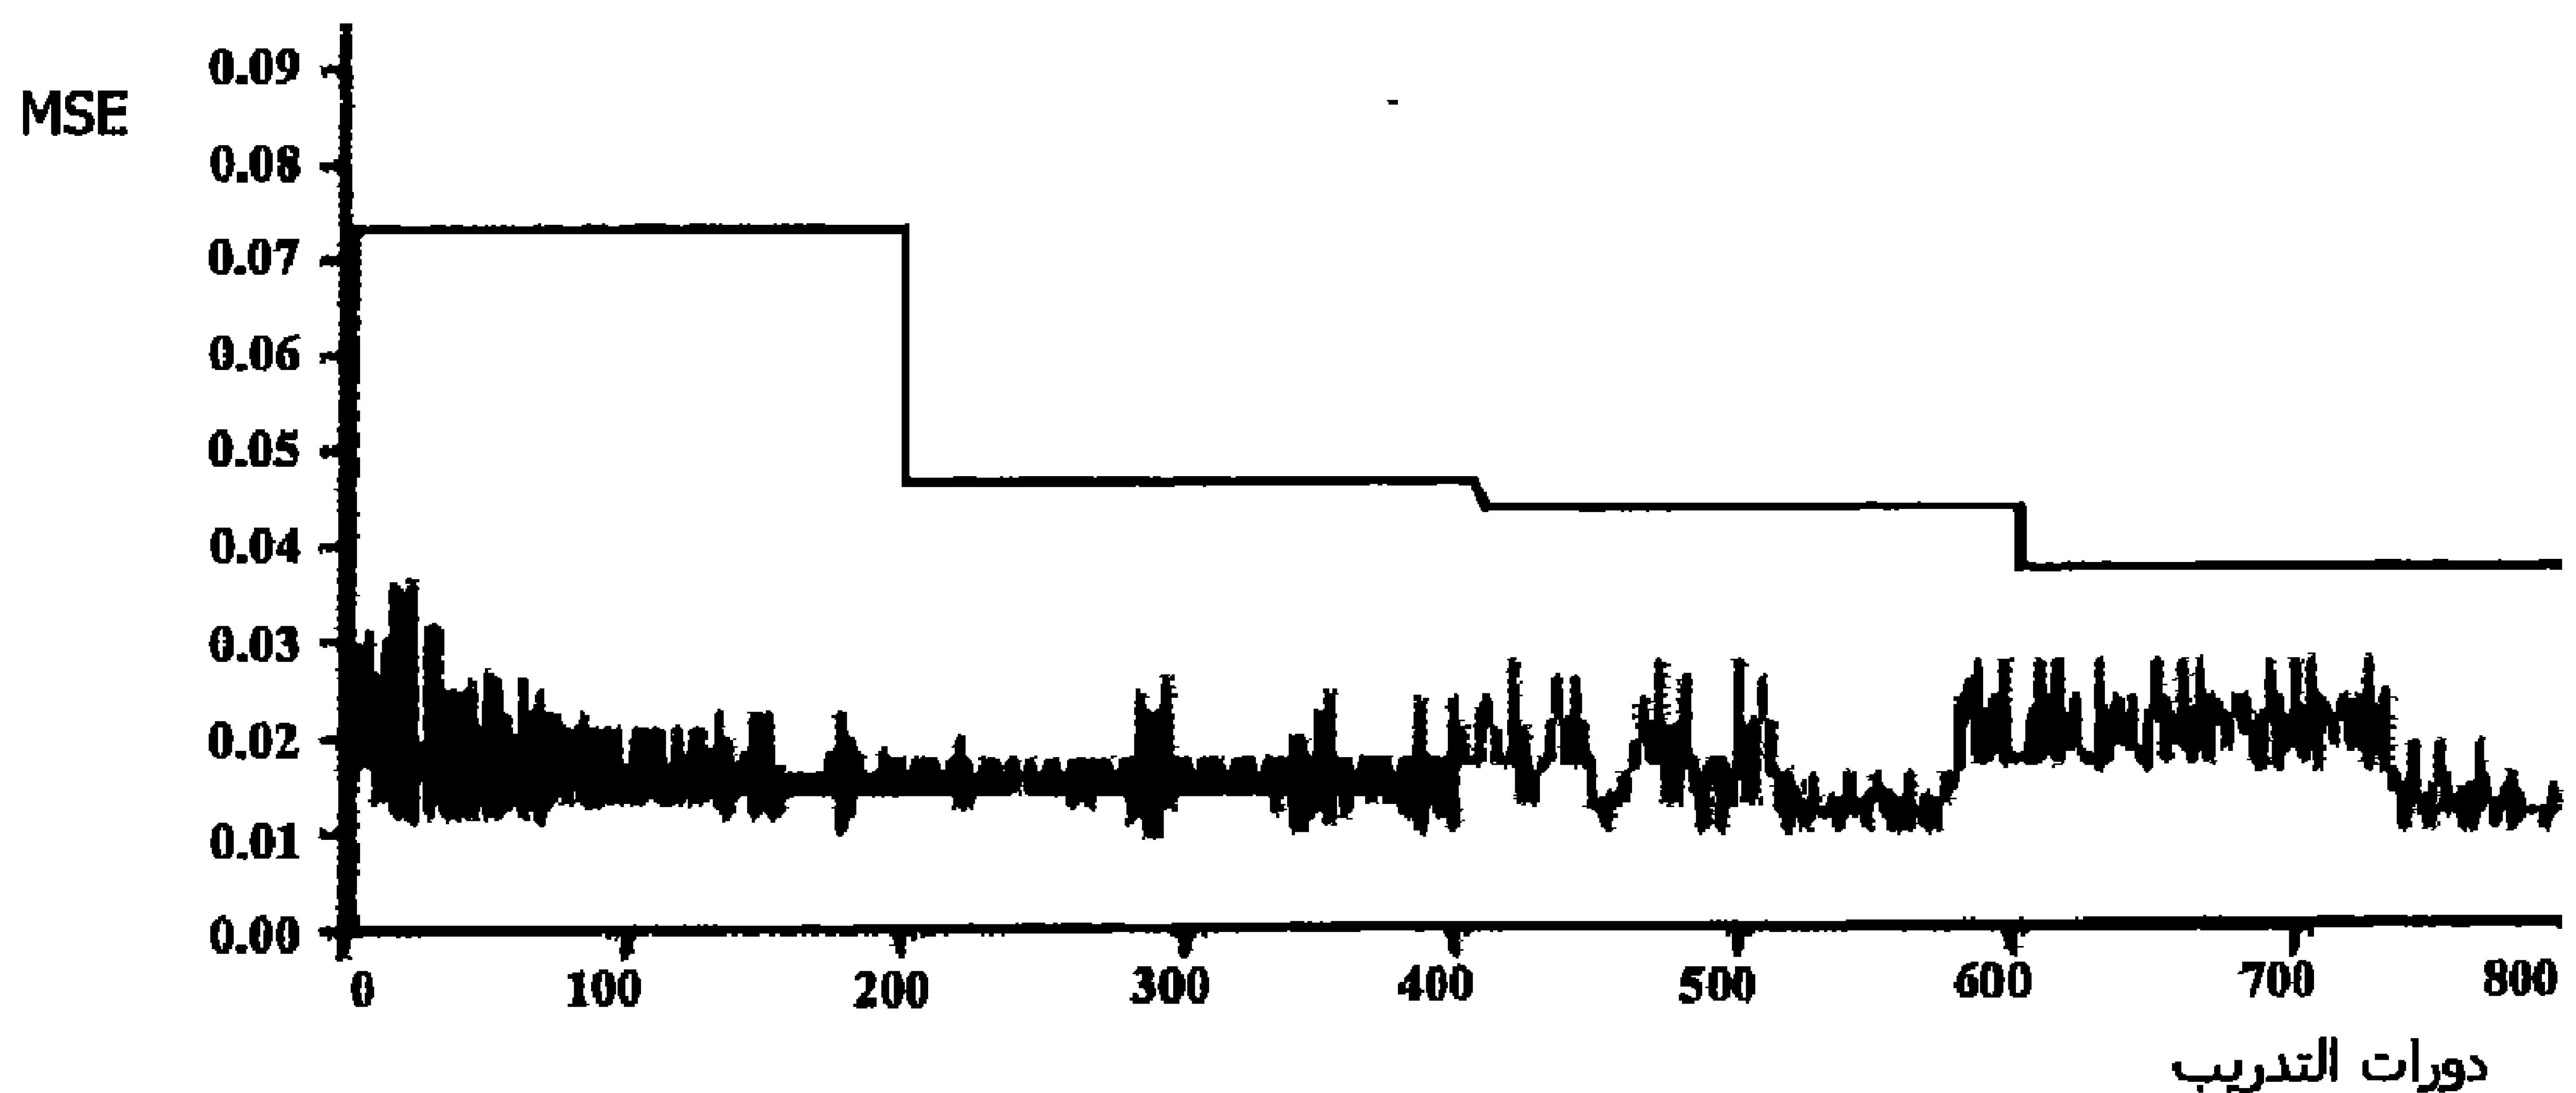
بنمط التدريب الجاري. يحدد البارامتر (نحّي) shuffle اختيار أشعة المراكز الابتدائية في بداية الإجراء. مع القيمة 1، تُختار المراكز عشوائياً من بين مجموعة أنماط التدريب (الجدول 2).

يظهر (الشكلان 6 و7)، بأن نتائج التدريب متماثلة لكلا إجرائي التهيئة، ولكن الخطأ الابتدائي هو أصغر بالإجراء 2. على أية حال، فإن تنبؤ معطيات الصلاحية أفضل بعض الشيء من أجل الإجراء 1، الذي بسببه سنختار لهذه الشبكة.

الشكل (6) *تمثيل خطأ MSE وفقاً لدورات التدريب لإجراء التهيئة 1. يشير الخط إلى خطأ مجموعة الصلاحية.*



الشكل (7) *تمثيل MSE وفقاً لدورات التدريب من أجل إجراء التهيئة 2. يشير الخط إلى خطأ مجموعة الصلاحية.*



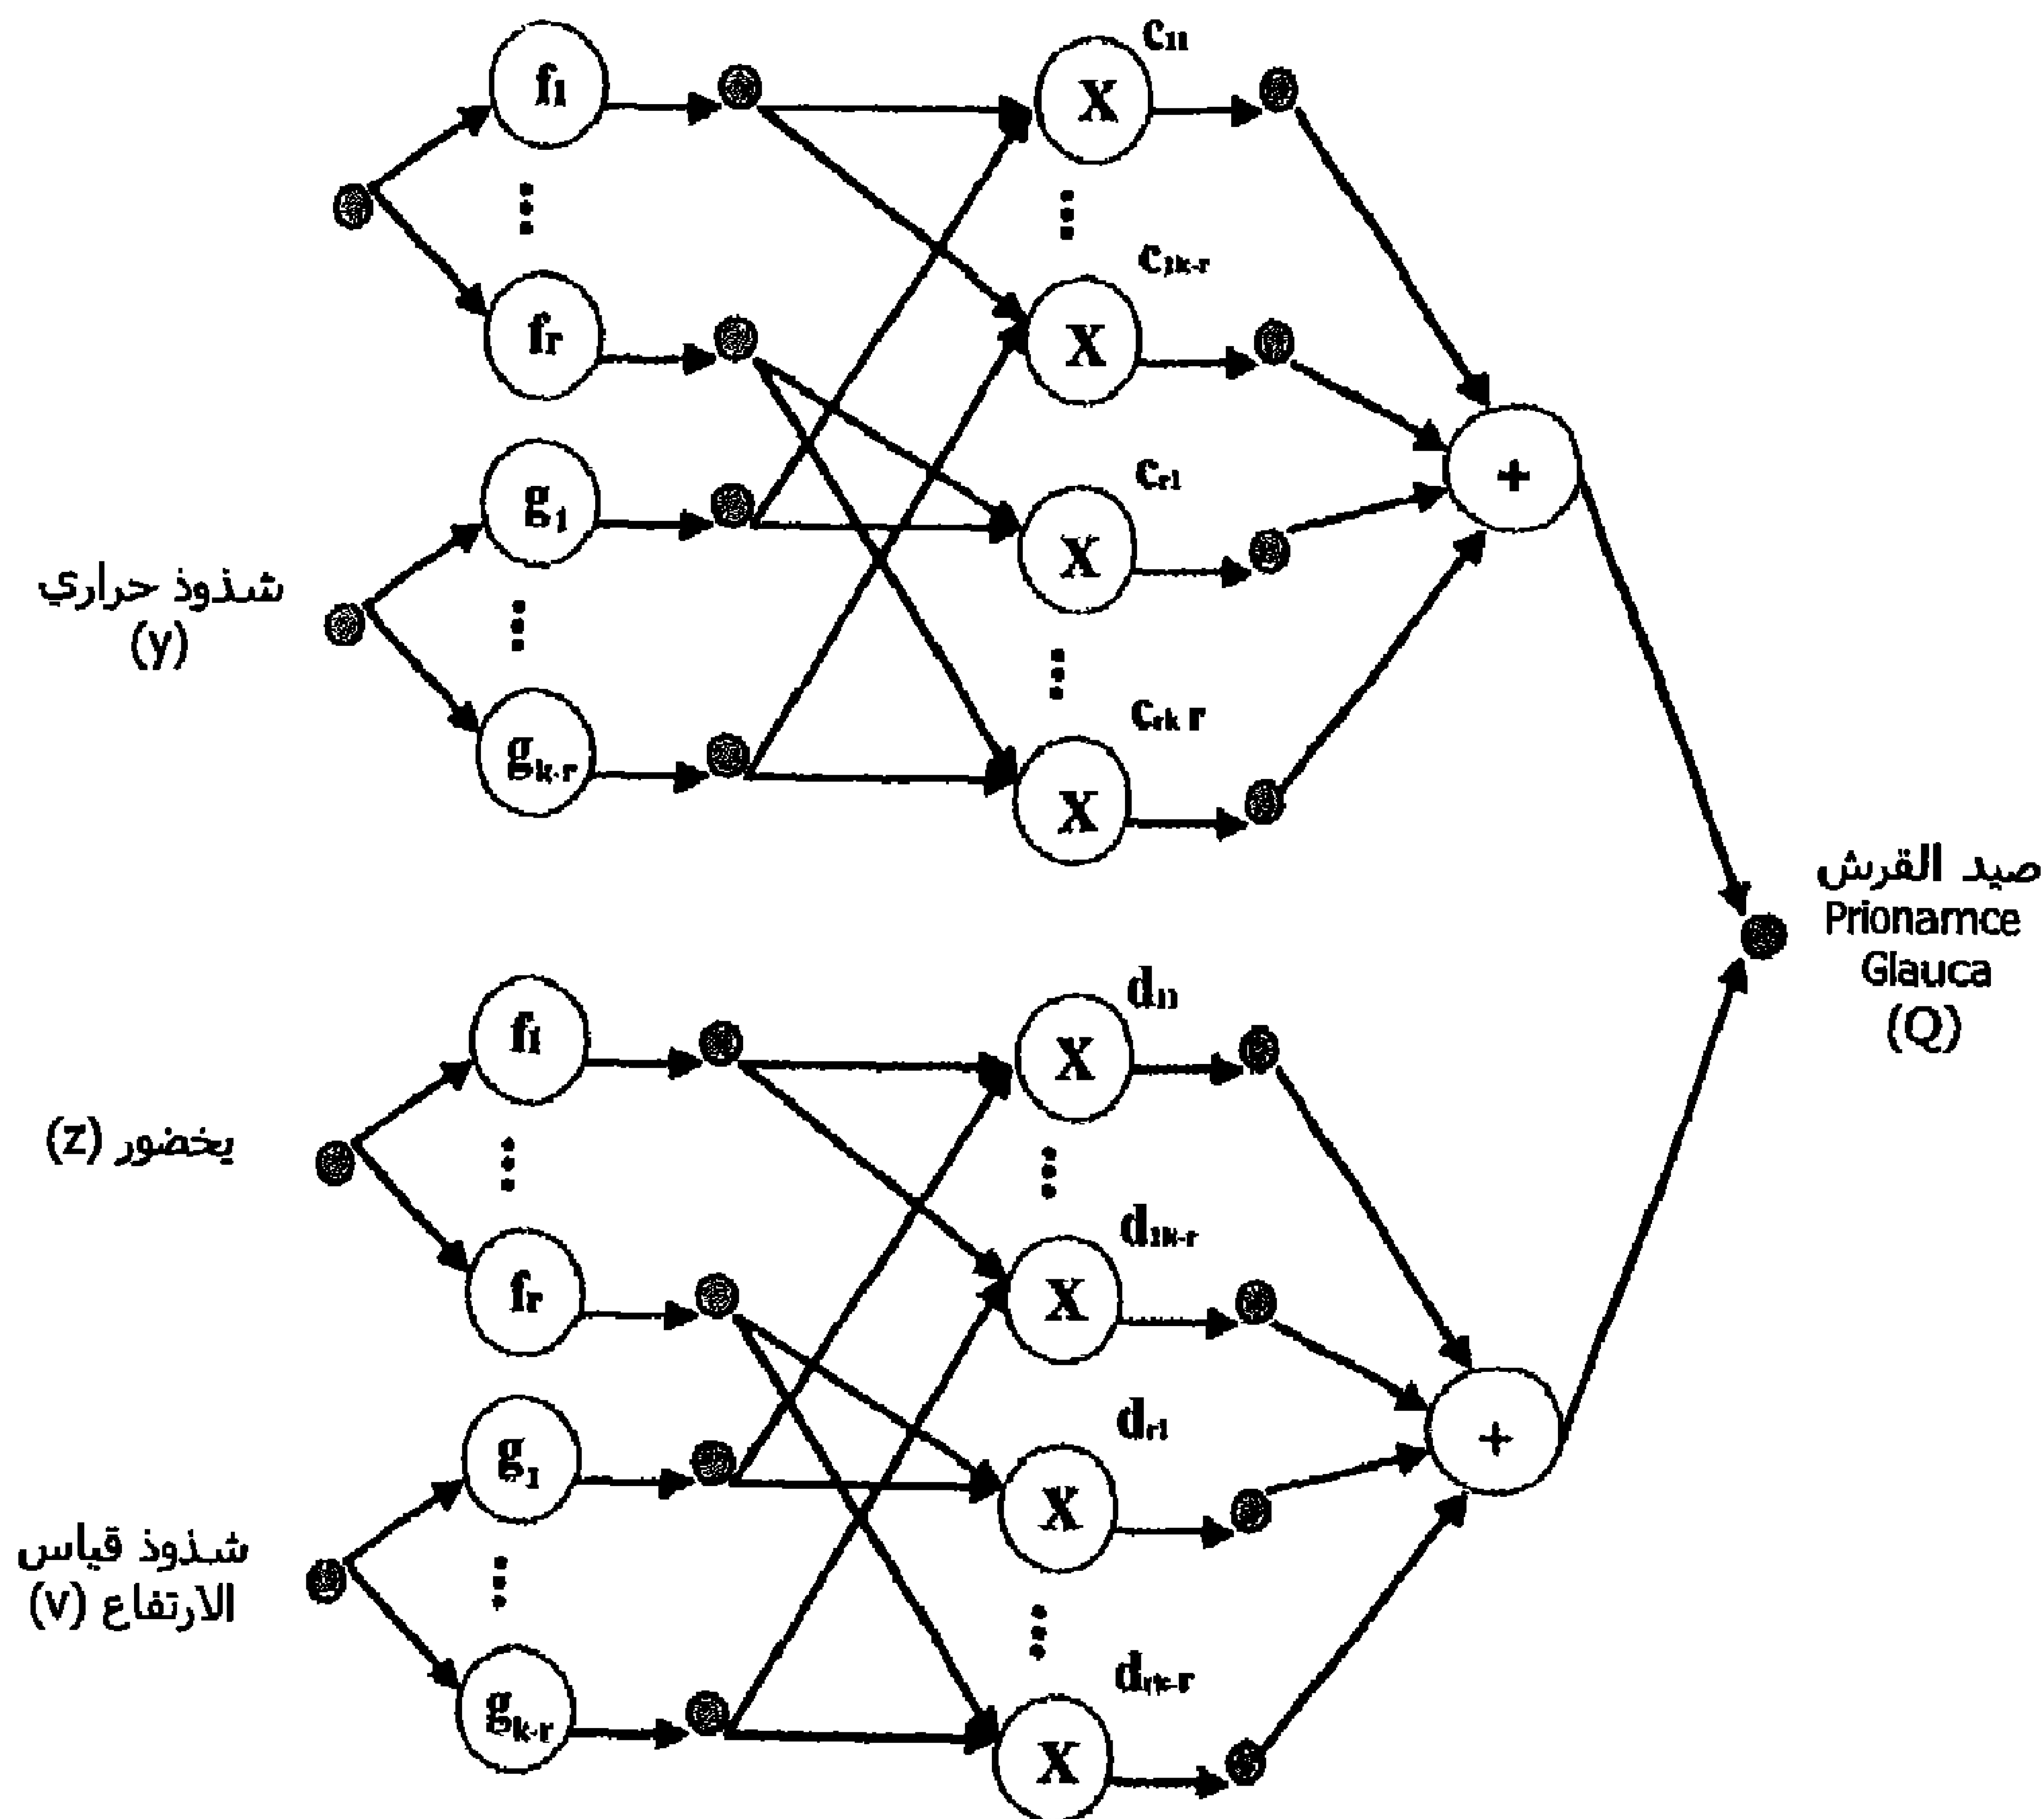
الجدول (2) البارامترات المستخدمة للبدء بالإجراء 2

دورات التعلم	a	نحيّ (shuffle)
20.000	0.5	1

نتائج الشبكات التابعية

كيفّنا نموذجاً ذا قابلية للفصل المشروح في Castillo and Gutierrez (1998) إلى مسألتنا. وتظهر طبولوجية الشبكة المقترحة من أجل التنبؤ بصيد القرش Prionace Glauca في (الشكل 8).

الشكل (8) *الشبكة التابعية من أجل التنبؤ بالصيد المعتمد على نموذج ذي قابلية للفصل*



يفترض هذا النموذج مسبقاً مجموعتين من التوابع: $\{f_i \mid i = 1, \dots r\}$ و$\{g_i \mid i = 1, \dots k\text{-}r\}$ التي يمكن أن يُحسب الخرج Q منها كالآتي:

$$Q=\sum_{i=1}^{r}\ \sum_{j=1}^{k-r} C_{ij}\, f_i(x) g_j(y)+\sum_{i=1}^{r}\ \sum_{j=1}^{k-r} d_{ij}\, f_i(z) g_j(v) \quad (1)$$

لحساب المعاملات الكافية C_{ij} وd_{ij}، يجب استخدام مجموعة التدريب، التي اُستخدمت للتو من أجل الشبكات العصبونية. تُوصف عملية التعلّم لشبكتنا في العلاقات التالية: يُعّرف الخطأ e_K لكل نمط كالآتي:

$$e_k = X_{ok} - Q = X_{ok} - \sum_{i=1}^{r}\sum_{j=1}^{k-r} C_{ij} f_i(x_k) g_j(y_k) + \sum_{i=1}^{r}\sum_{j=1}^{k-r} d_{ij} f_i(z_k) g_j(v_k) \quad (2)$$

الهدف من تدريبنا، هو تخفيض مجموع أخطاء كافة الأنماط إلى الحد الأدنى، أي تخفيض E إلى الحد الأدنى:

$$E = \sum_{k=1}^{n} e_k^2 \qquad (3)$$

حيث n – هو عدد أنماط مجموعة التدريب.

باستخدام طريقة المربعات الصغرى، فإن البارامترات التي تخفض E إلى الحد الأدنى، يجب أن يكون حلاً لجملة المعادلات التالية:

$$\begin{cases} \dfrac{\partial E}{\partial C_{pq}} = 2\sum_{k=1}^{n} e_k f_p(x_k) g_q(y_k) = 0 \\ \dfrac{\partial E}{\partial d_{pq}} = 2\sum_{k=1}^{n} e_k f_p(z_k) g_q(v_k) = 0 \end{cases} \qquad (4)$$

حيث: P = 1, ..., r وq = 1, ..., r-s

بتعويض e_k في العلاقات (2, 3)، نحصل على جملة المعادلات التالية:

$$\begin{cases} \dfrac{\partial E}{\partial C_{pq}} = 2\sum_{k=1}^{n} \left(\sum_{i=1}^{r}\sum_{j=1}^{r} C_{ij} f_i(x_k) g_j(y_k) + \sum_{i=1}^{r}\sum_{j=1}^{k-r} d_{ij} f_i(z_k) g_j(v_k) \right) e_k f_p(x_k) q_q(y_k) = 0 \\ \dfrac{\partial E}{\partial d_{pq}} = 2\sum_{k=1}^{n} \left(\sum_{i=1}^{r}\sum_{j=1}^{r} C_{ij} f_i(x_k) g_j(y_k) + \sum_{i=1}^{r}\sum_{j=1}^{k-r} d_{ij} f_i(z_k) g_j(v_k) \right) e_k f_p(z_k) q_q(v_k) = 0 \end{cases} \qquad (5)$$

حيث: P = 1, ..., r، q = 1, ..., r-s

لأسباب التماسك فإن أنماط التدريب مماثلة لتلك التي دربت الشبكات العصبونية في القسم السابق. تخصص الشبكات التابعية لحل المسائل بالنموذج الرياضي، ولكن طالما أن حالتنا لا تقدم نموذجاً، فإننا نختار مجموعة كثير الحدود الأولية كأساس لحل الجملة.

تم اختيار مجموعات التوابع التالية:

- **الحالة 1**: $\{f_i\} = \{1, x, x^2, x^3\}$ و $\{g_i\} = \{x, x^2, x^3, x^4\}$.
- **الحالة 2**: $\{f_i\} = \{1, x, x^2, x^3, x^4\}$ و $\{g_i\} = \{x, x^2, x^3, x^4, x^5\}$.
- **الحالة 3**: $\{f_i\} = \{1, x, x^2, x^3, x^4, x^5\}$ و $\{g_i\} = \{x, x^2, x^3, x^4, x^5, x^6\}$.

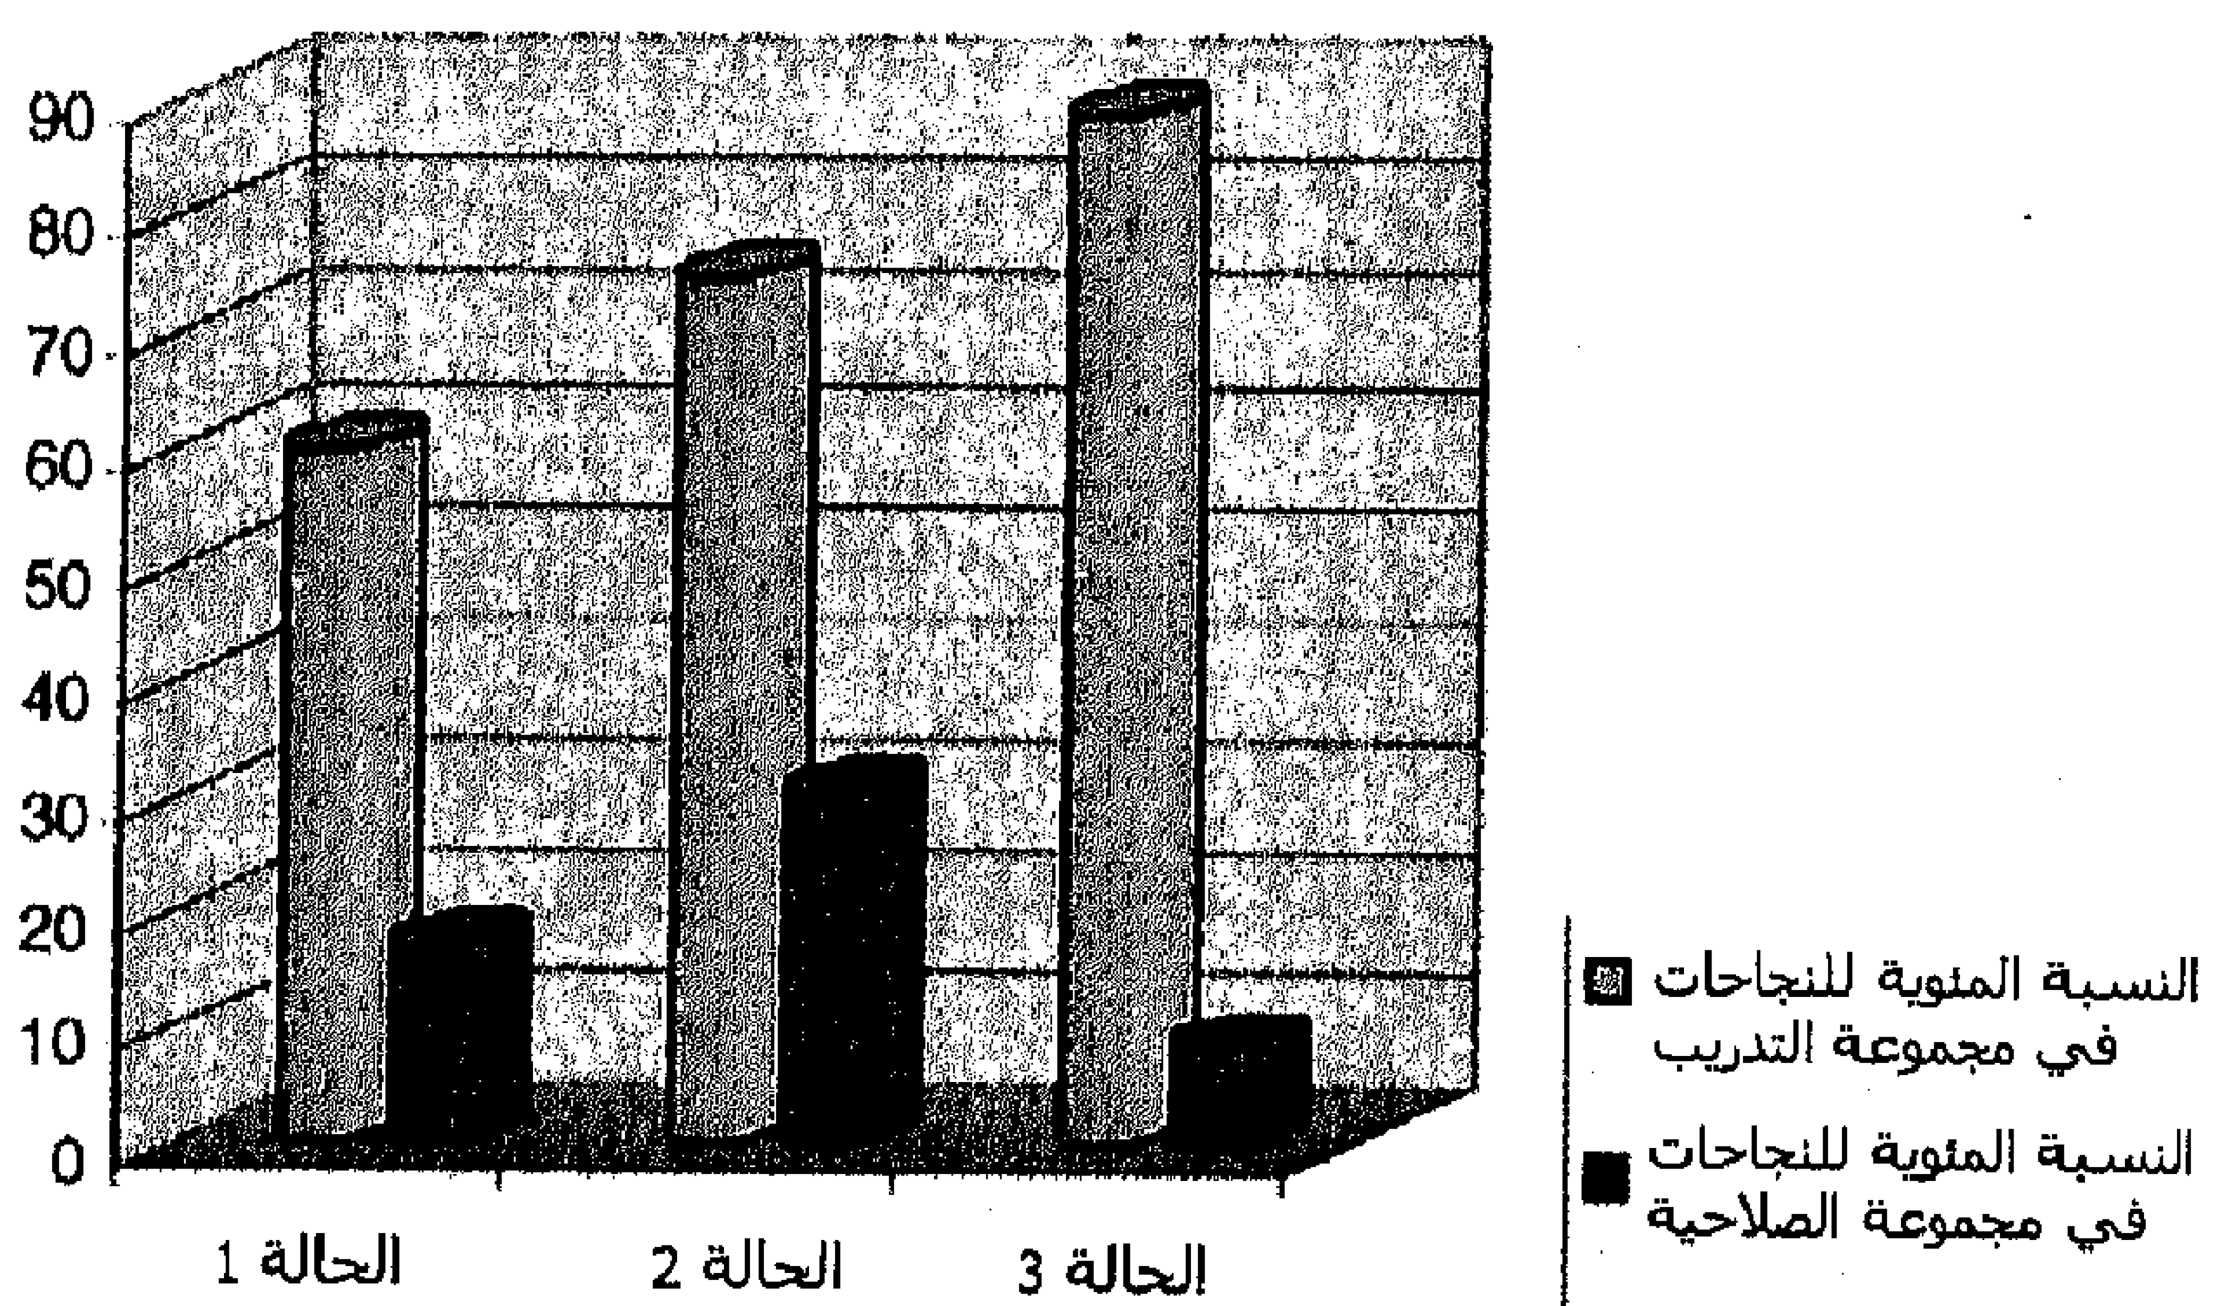
يجب أن نكون حذرين جداً عند اختيار مجموعات التوابع، لأن محدد مصفوفة المعاملات قد يمتلك عمودين متماثلين. وهذا هو سبب عدم احتواء المجموعة $\{g_i\}$ على التابع الأولي 1.

يعكس القسم التالي نتائج كل حالة:

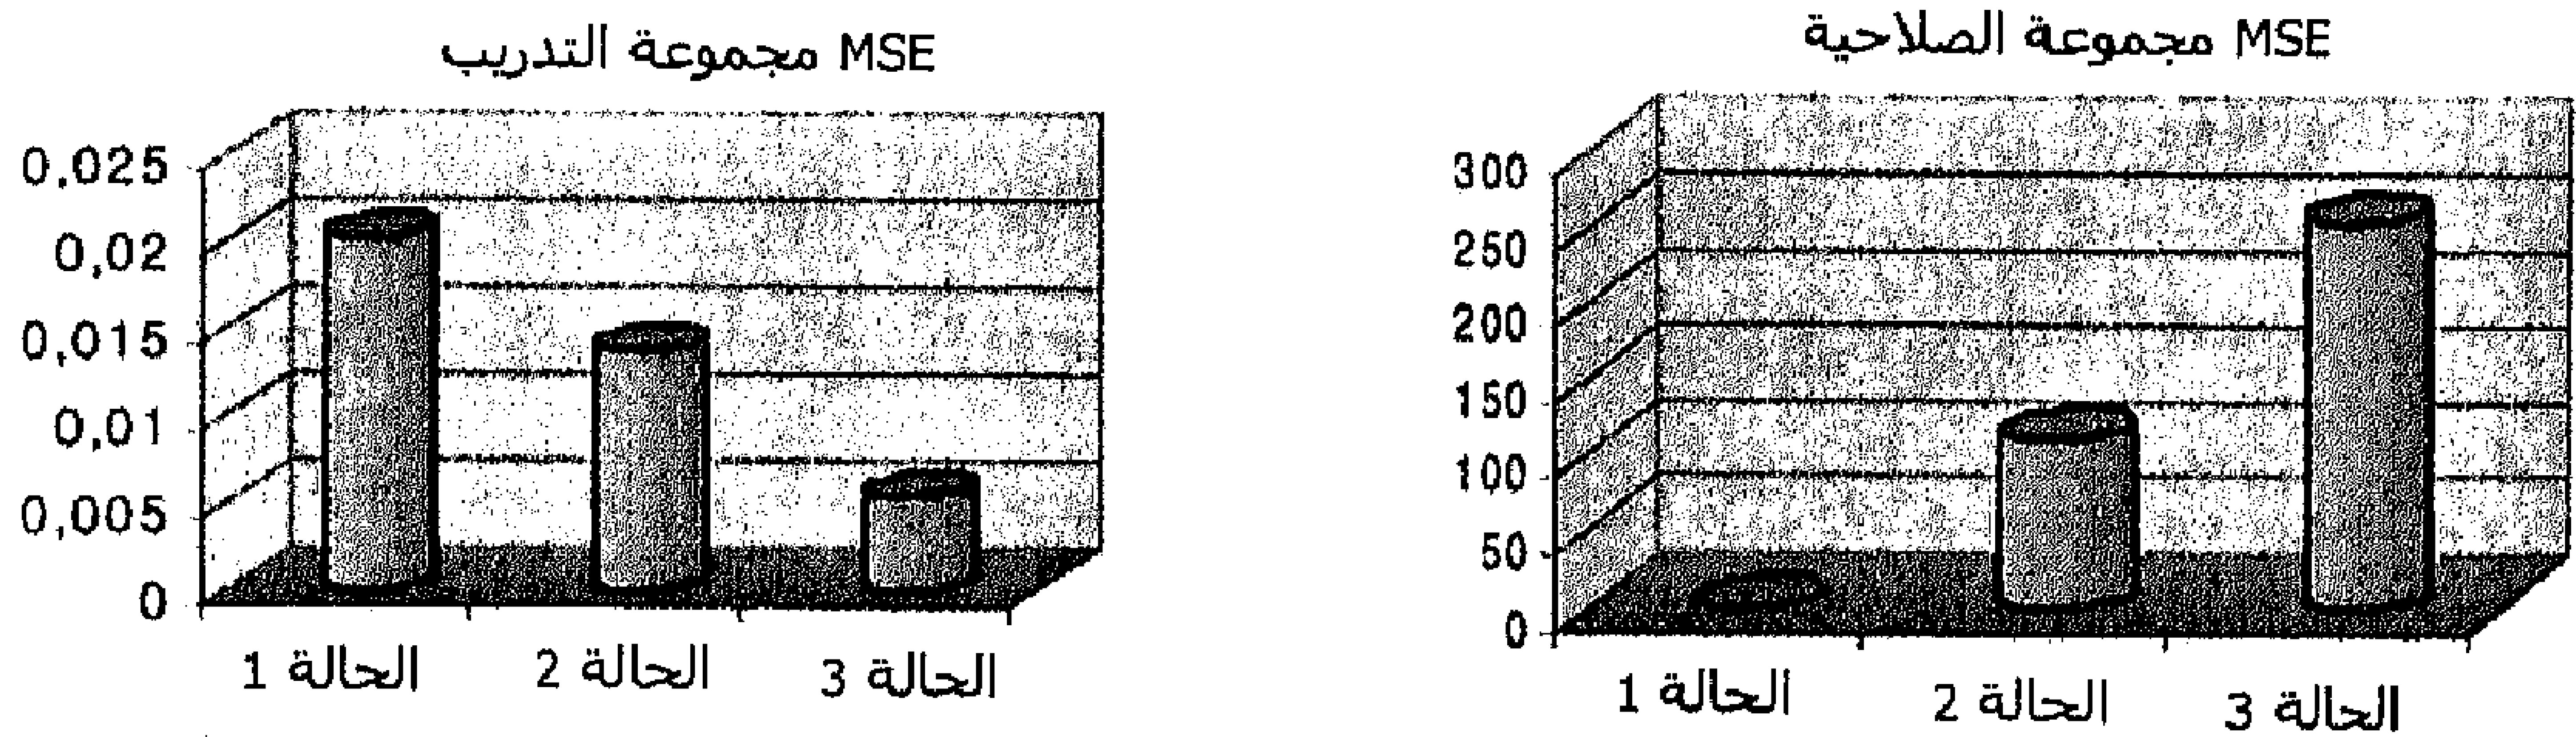
نبدأ بتقييم نجاح مجموعات الصلاحية والتدريب. يبين (الشكل 9)، بأن التعلّم الأفضل يوافق بداهةً توابع الحالة 2. نسبة النجاح المئوية هي مجرد توجيهية: حتى بمعدل نجاح عال يمكن أن يكون الخطأ العام كبيراً جداً. وبالتالي، فإننا نقيس مستوى التعلم للأنظمة المدرّسة بالخطأ التربيعي الوسطي (MSE).

يمثل (الشكل 10) MSE لمجموعات الصلاحية والتدريب في كلٍّ من الحالات الثلاث. يمكننا ملاحظة أن MSE التدريب تساوي وحتى أعلى من MSE للشبكات العصبونية. وهي نتائج منطقية، بما أنه كلما كانت التوابع المستخدمة أكثر، فإن النموذج الأقرب الذي ينتج من الشبكة التابعية يكون أقرب إلى معطيات التدريب. على أية حال، يكمن قصدنا في امتلاك الشبكة، التي تستخلص المعرفة اللازمة لتوقع المخرجات من المدخلات، والتحكم بهذه الحقيقة بواسطة النتائج المُكتسبة من خلال مجموعة الصلاحية.

الشكل (9) *مقارنة نتائج مجموعات الصلاحية والتدريب.*



الشكل (10) *MSE لمجموعات الصلاحية والتدريب*



وُجد MSE الأقل لمجموعات الصلاحية في الحالة 1 (0.404)، بينما وصل MSE في الحالتين 3, 2 إلى القيم التي بالكاد تكون مقبولة. الوضع غير منسجم مع (الشكل 9)، حيث رصدنا اختلافات عددية هامة بين القيم الحقيقية والقيم التنبؤية في الحالات، التي لم تُعتبر ناجحة. تصبح هذه الاختلافات أقل أهمية، إذا دربنا الشبكة التابعية بقاعدة التوابع التي توافق الحالة 1. وقد وجدنا أن الخطأ في مجموعة الصلاحية يؤثر سلباً على النتائج المكتسبة بواسطة الشبكات العصبونية المذكورة للتو. والحقيقة أنه، لا يوجد نموذج رياضي توضيحي للمسألة يشرح هذه الظاهرة. تكون الشبكات التابعية فعالة بشكل خاص في الحالة، التي لها هذا النموذج التحتي. على الرغم من هذا، يبقى من المثير مقارنة سلوك البنى الهندسية للتعلم الكلاسيكي والحديث.

ANFIS

طبقنا أنظمة ANFIS من الطراز 3 (Jang, 1992; 1993; Takagi - Sugeno, 1992, 1993) باستخدام الأنماط المطبقة للشبكات التابعية والعصبونية كمجموعات صلاحية وتدريب. بغية اكتشاف الطبولوجية الأفضل لنظامنا، صممنا ANFIS بالمواصفات التالية:

- **الحالة 1**: تابعين عضويين (أو توابع مميزة) لكل متغير. الخرج هو من المرتبة 0 (تابع ثابت).
- **الحالة 2**: أربعة توابع عضوية لكل متغير. الخرج هو من المرتبة 0 (تابع ثابت).
- **الحالة 3**: ثلاثة توابع عضوية من أجل المتغيرات SST، والشذوذ الارتفاعي، واثنان من أجل اليخضور والشذوذ الحراري. الخرج هو من المرتبة 0 (تابع ثابت).
- **الحالة 4**: تابعان عضويان من أجل المتغيرات SST والشذوذ الارتفاعي، وثلاثة من أجل اليخضور والشذوذ الحراري. الخرج هو من المرتبة 0 (تابع ثابت).

- **الحالة 5**: ثلاثة توابع عضوية لكل متغير. الخرج هو من المرتبة 0 (تابع ثابت).
- **الحالة 6**: تابعان عضويان لكل متغير. الخرج هو من المرتبة 1 (تابع خطي).
- **الحالة 7**: أربعة توابع عضوية لكل متغير الخرج هو من المرتبة 1 (تابع خطي).
- **الحالة 8**: ثلاثة توابع عضوية من أجل المتغيرات SST والشذوذ الارتفاعي، واثنان من أجل اليخضور والشذوذ الحراري. الخرج هو من المرتبة 1 (تابع خطي).
- **الحالة 9**: تابعان عضويان من أجل المتغيرات SST والشذوذ الارتفاعي، وثلاثة من أجل اليخضور والشذوذ الحراري. الخرج هو من المرتبة 1 (تابع خطي).
- **الحالة 10**: ثلاثة توابع عضوية لكل متغير. الخرج هو من المرتبة 1 (تابع خطي).

في كافة الحالات تمتلك الأنظمة المُطورة المواصفات التالية في العموم:

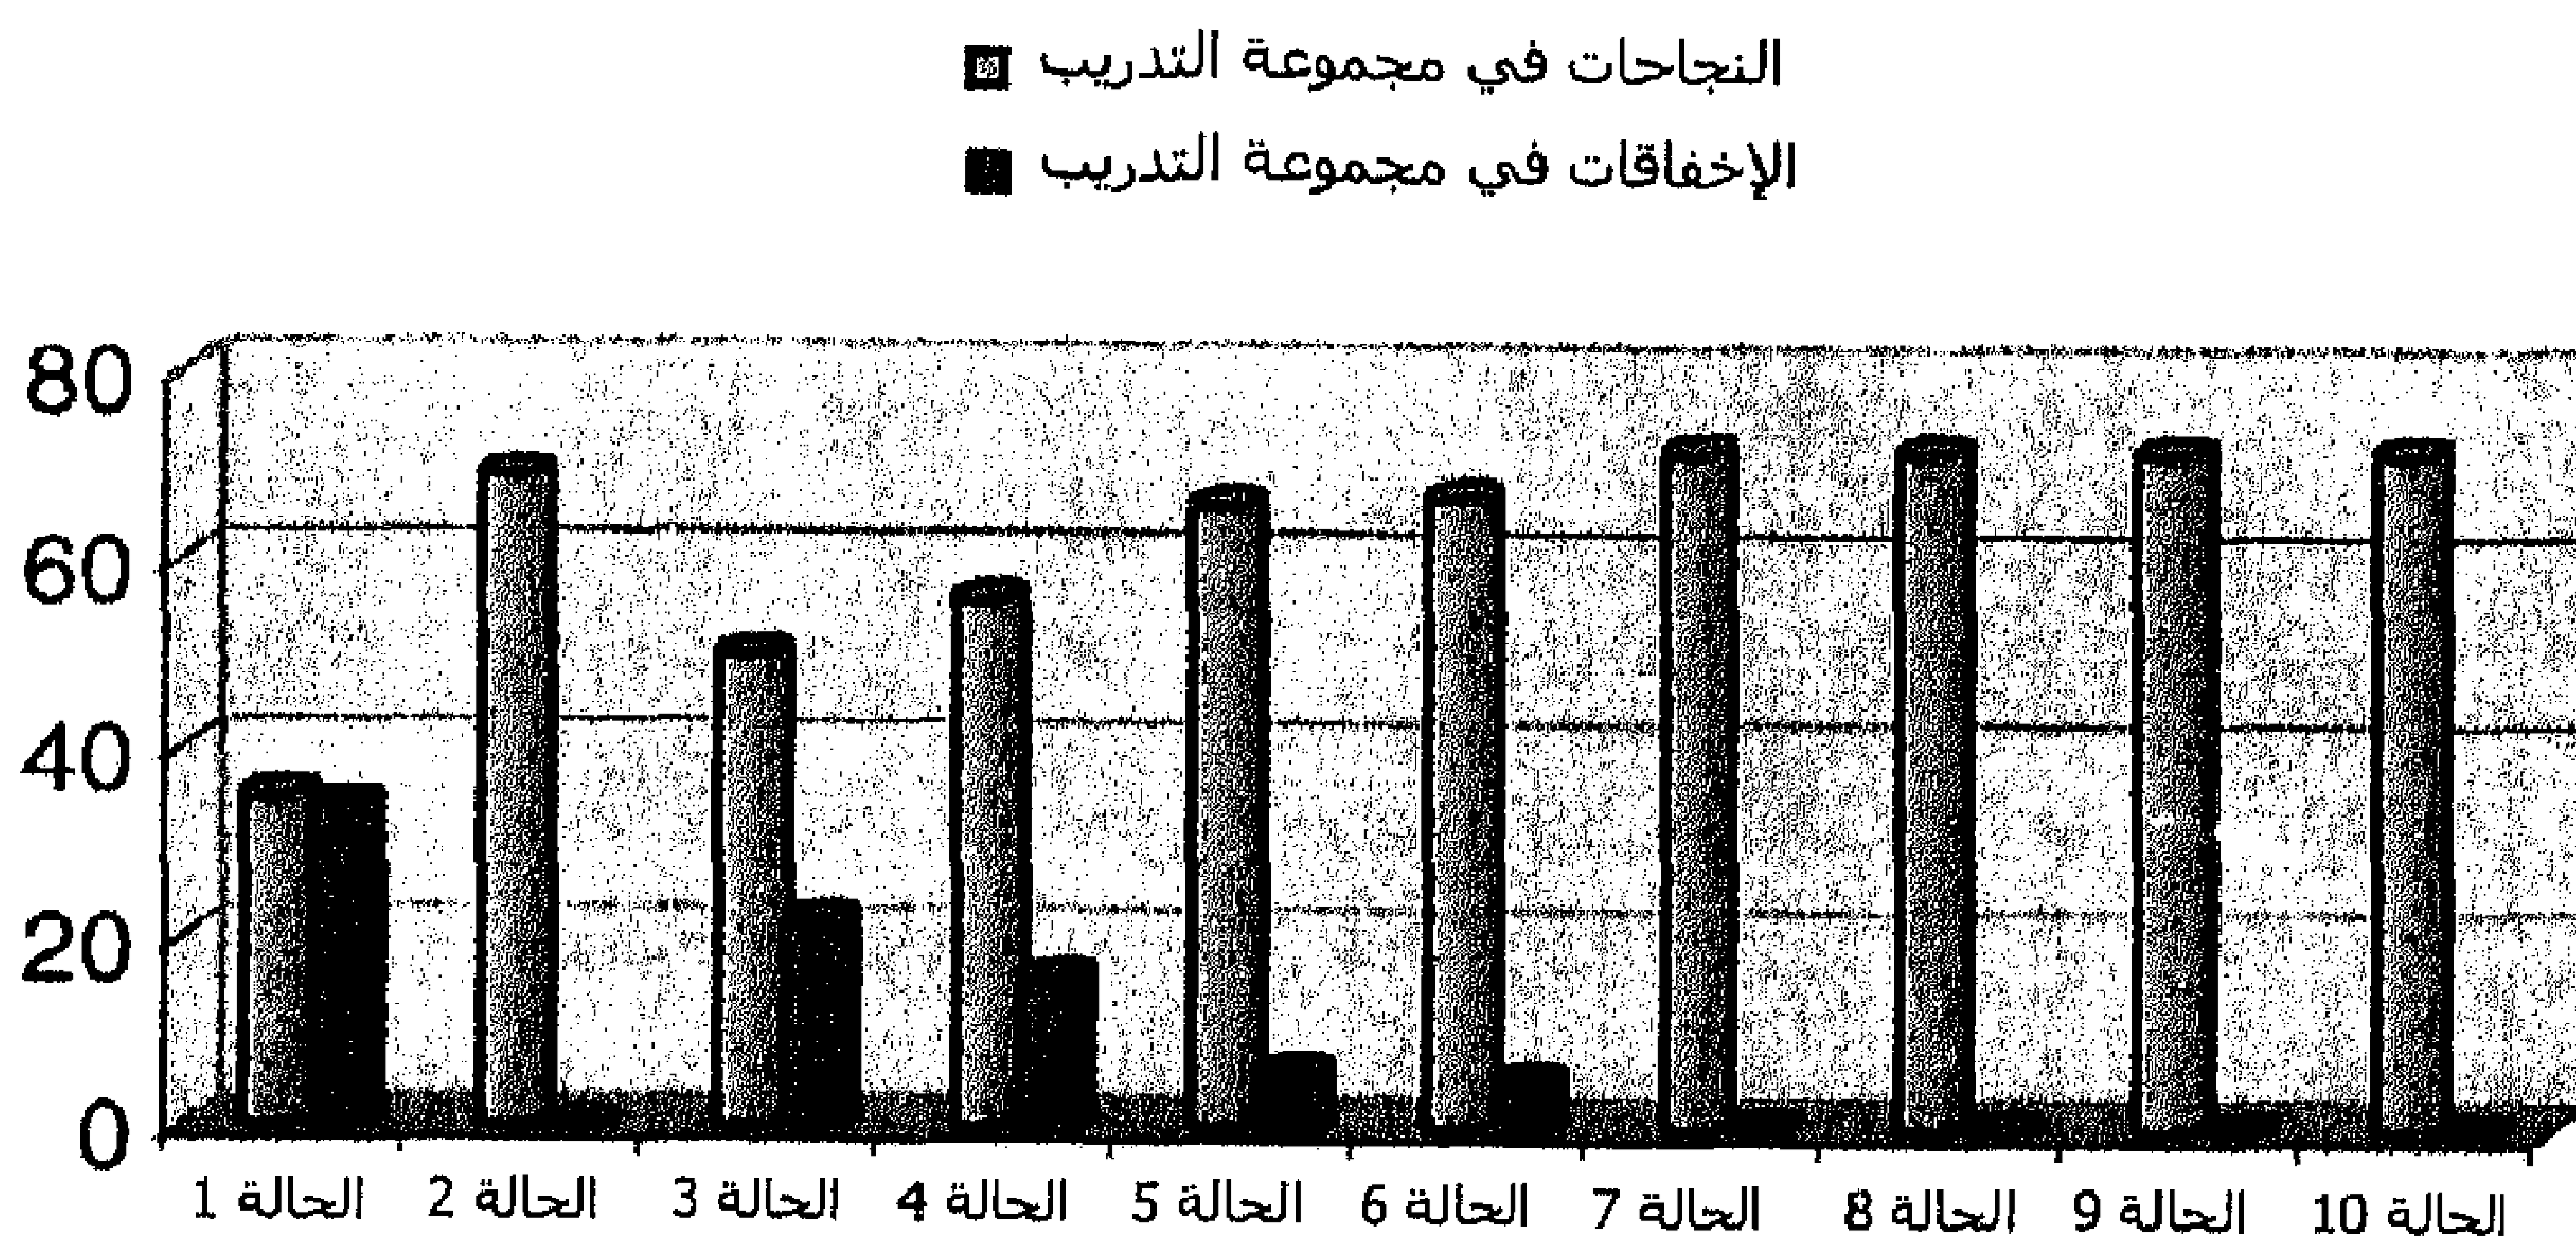
- قاعدة AND المستخدمة = إنتاج
- قاعدة OR المستخدمة احتمالية OR = ab - b + a
- طريقة إزالة التقويم ⇐ مجموع مُثقل متوسط.
- طريقة تدريب هجينة مشروحة لاحقاً.
- توابع غاوس عضوية.

استمر التدريب حتى بقي خطأ أنماط التدريب ثابتاً. وبشكل متوازٍ، تم التحكم بالخطأ في مجموعة الصلاحية والنجاح ومعدل الخطأ. يُعتبر تنبؤ نظامنا ناجح، إذاً اختلف أقل من 10% من قيمة الصيد الأعظمية. بما أننا سوّينا كافة معطيات الصيد، فإن القيم تقع في المجال [1، 0]، ويكون هذا هو تنبؤنا وفقاً لهذا المعيار. حصلنا على معادلات الخطأ والنجاح في مجموعة التدريب انظر (الشكل 11).

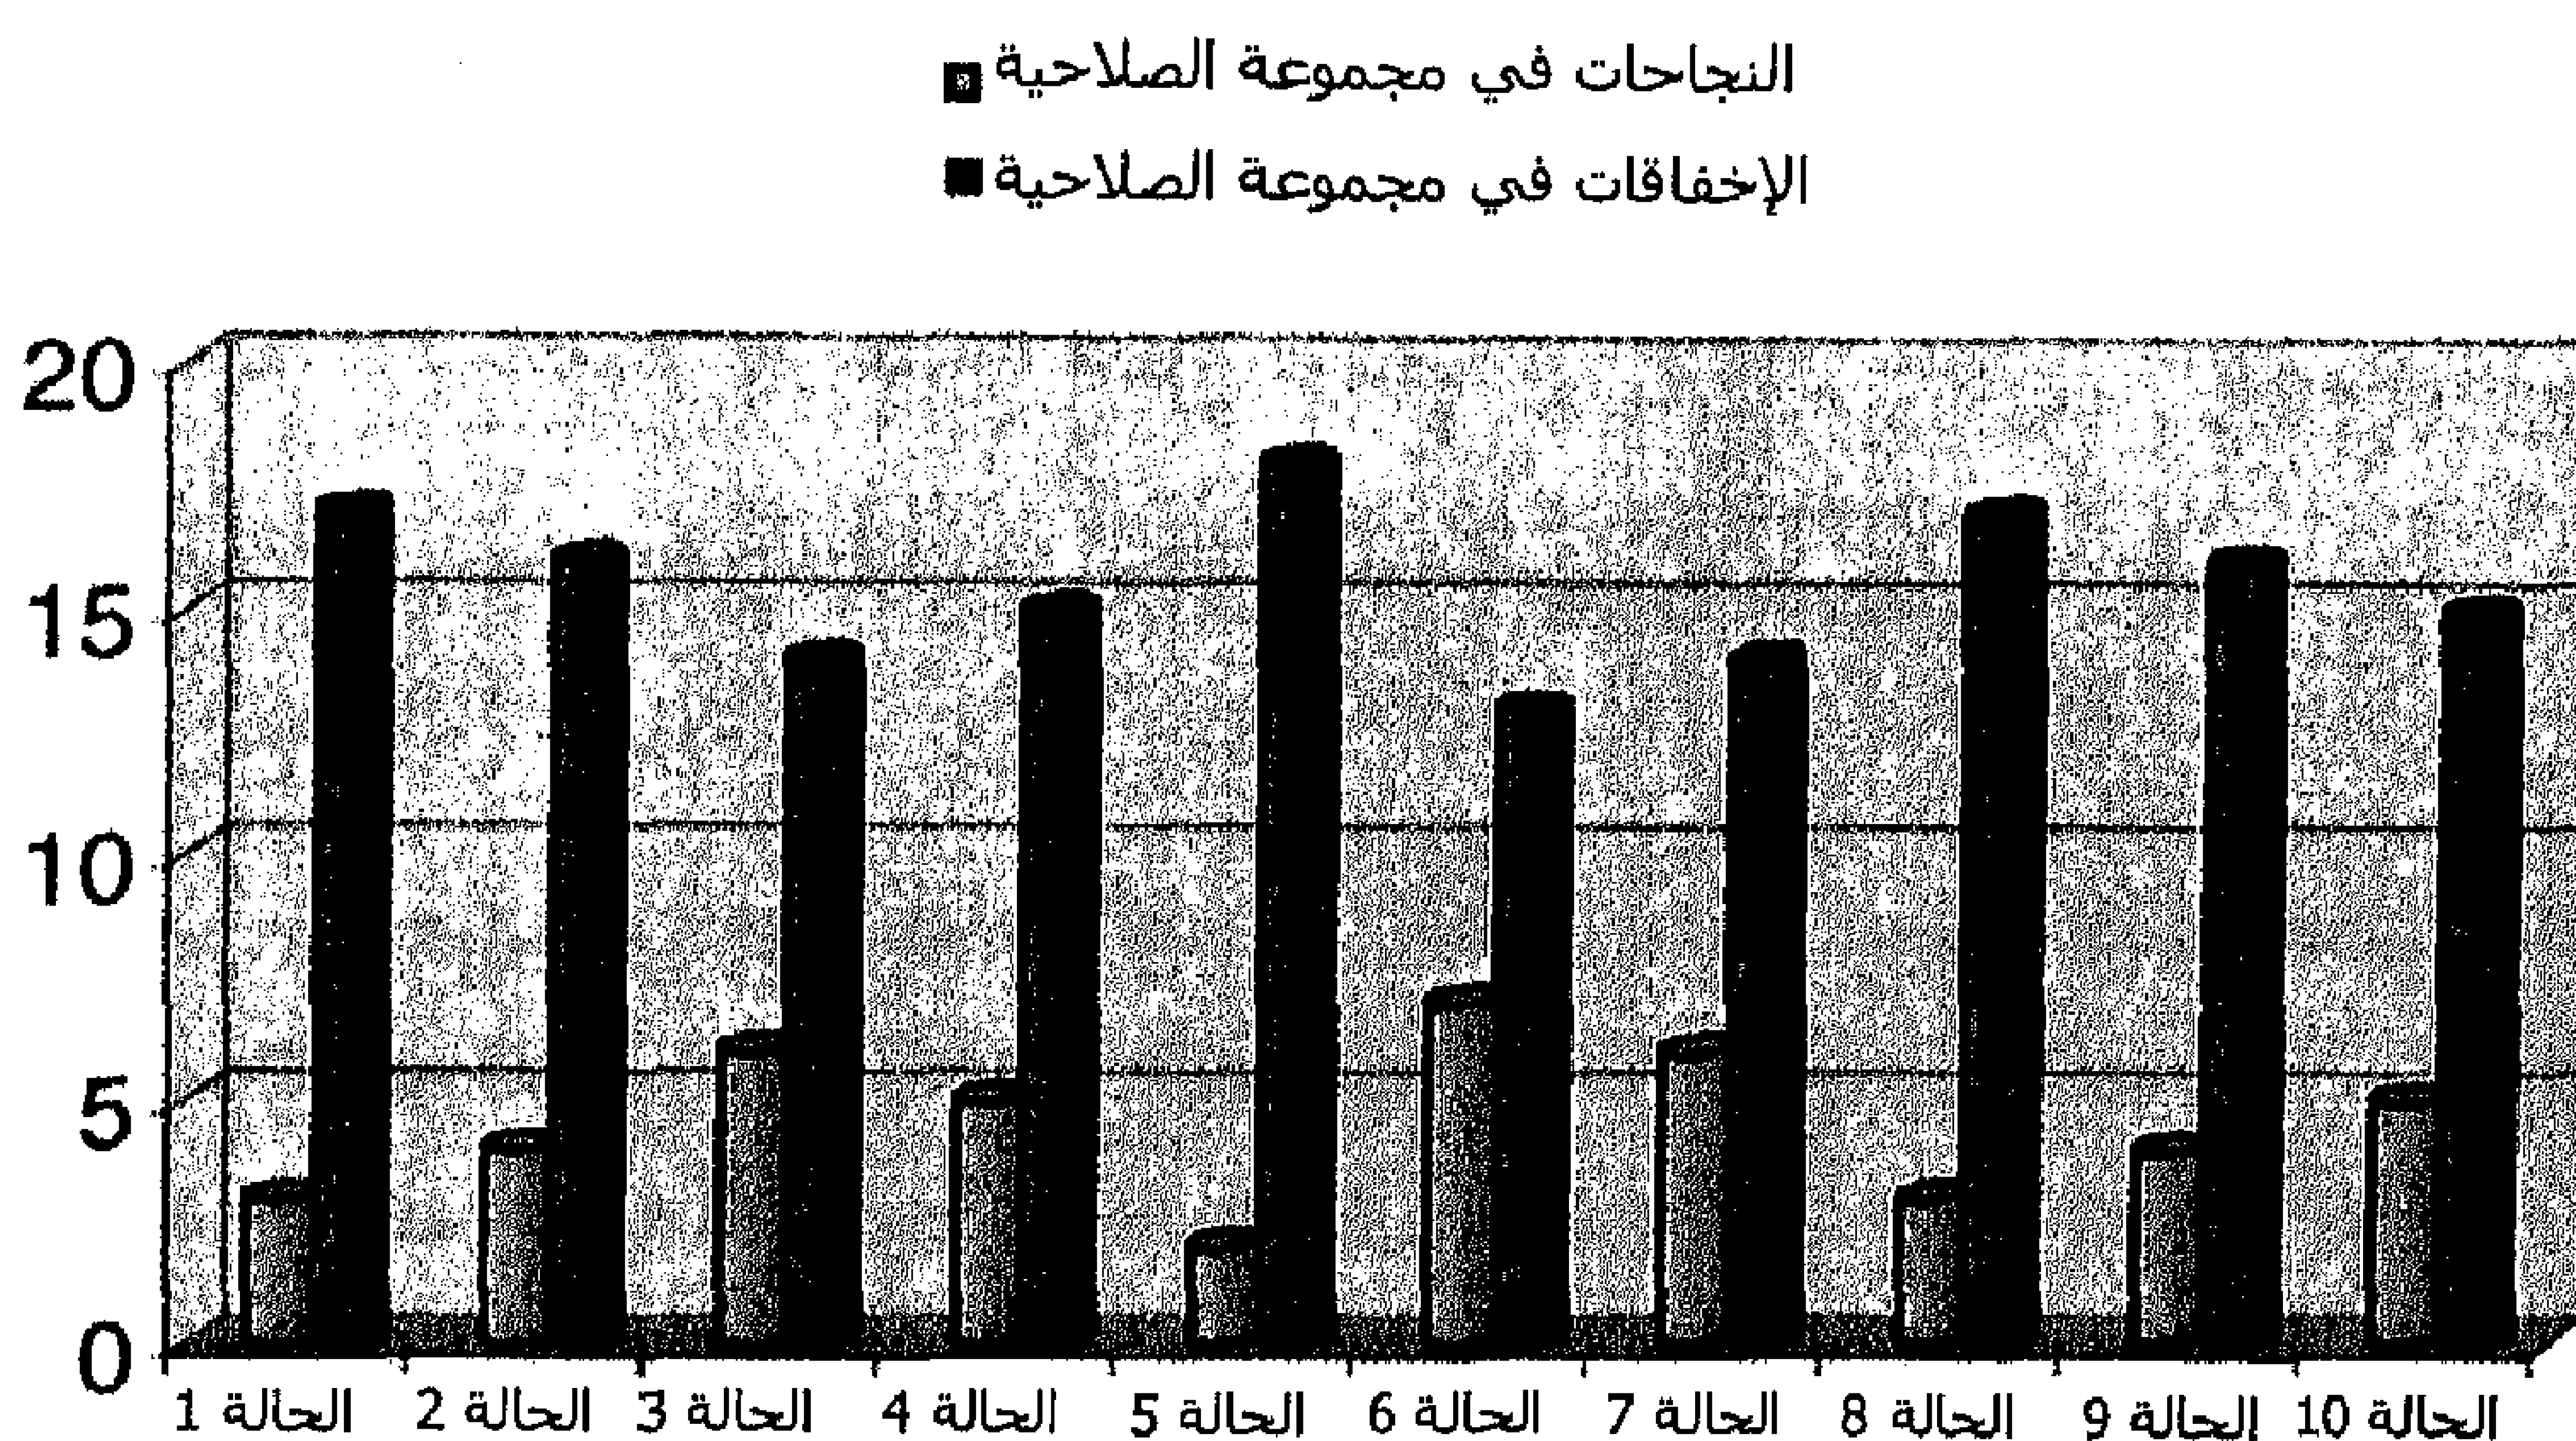
في (الشكل 11) يمكننا ملاحظة أن معدل النجاح بعد التدريب يكون واعداً في عدة حالات (2، 7، 8، 9، 10). فقط في الحالة الأولى يحتل عدد الأخطاء منزلةً متساوية مع مرتبة النجاحات. وهذا – على أية حال – هو مجرد قياس توجيهي: إذا أردنا معرفة قدرة التعلّم لنظامنا، يجب علينا دراسة معطيات مجموعة الصلاحية وبشكل خاص MSE الخاص.

كانت النتائج أقل إيجابية من أجل مجموعة أنماط الصلاحية. يبين (الشكل 12)، أن معدل نجاح التنبؤ لا يتفوق أبداً على معدل الخطأ.

الشكل (11) *مقارنة معدل الخطأ والنجاح في مجموعة التدريب*



الشكل (12) *مقارنة معدل الخطأ ومعدل النجاح في مجموعة الصلاحية*

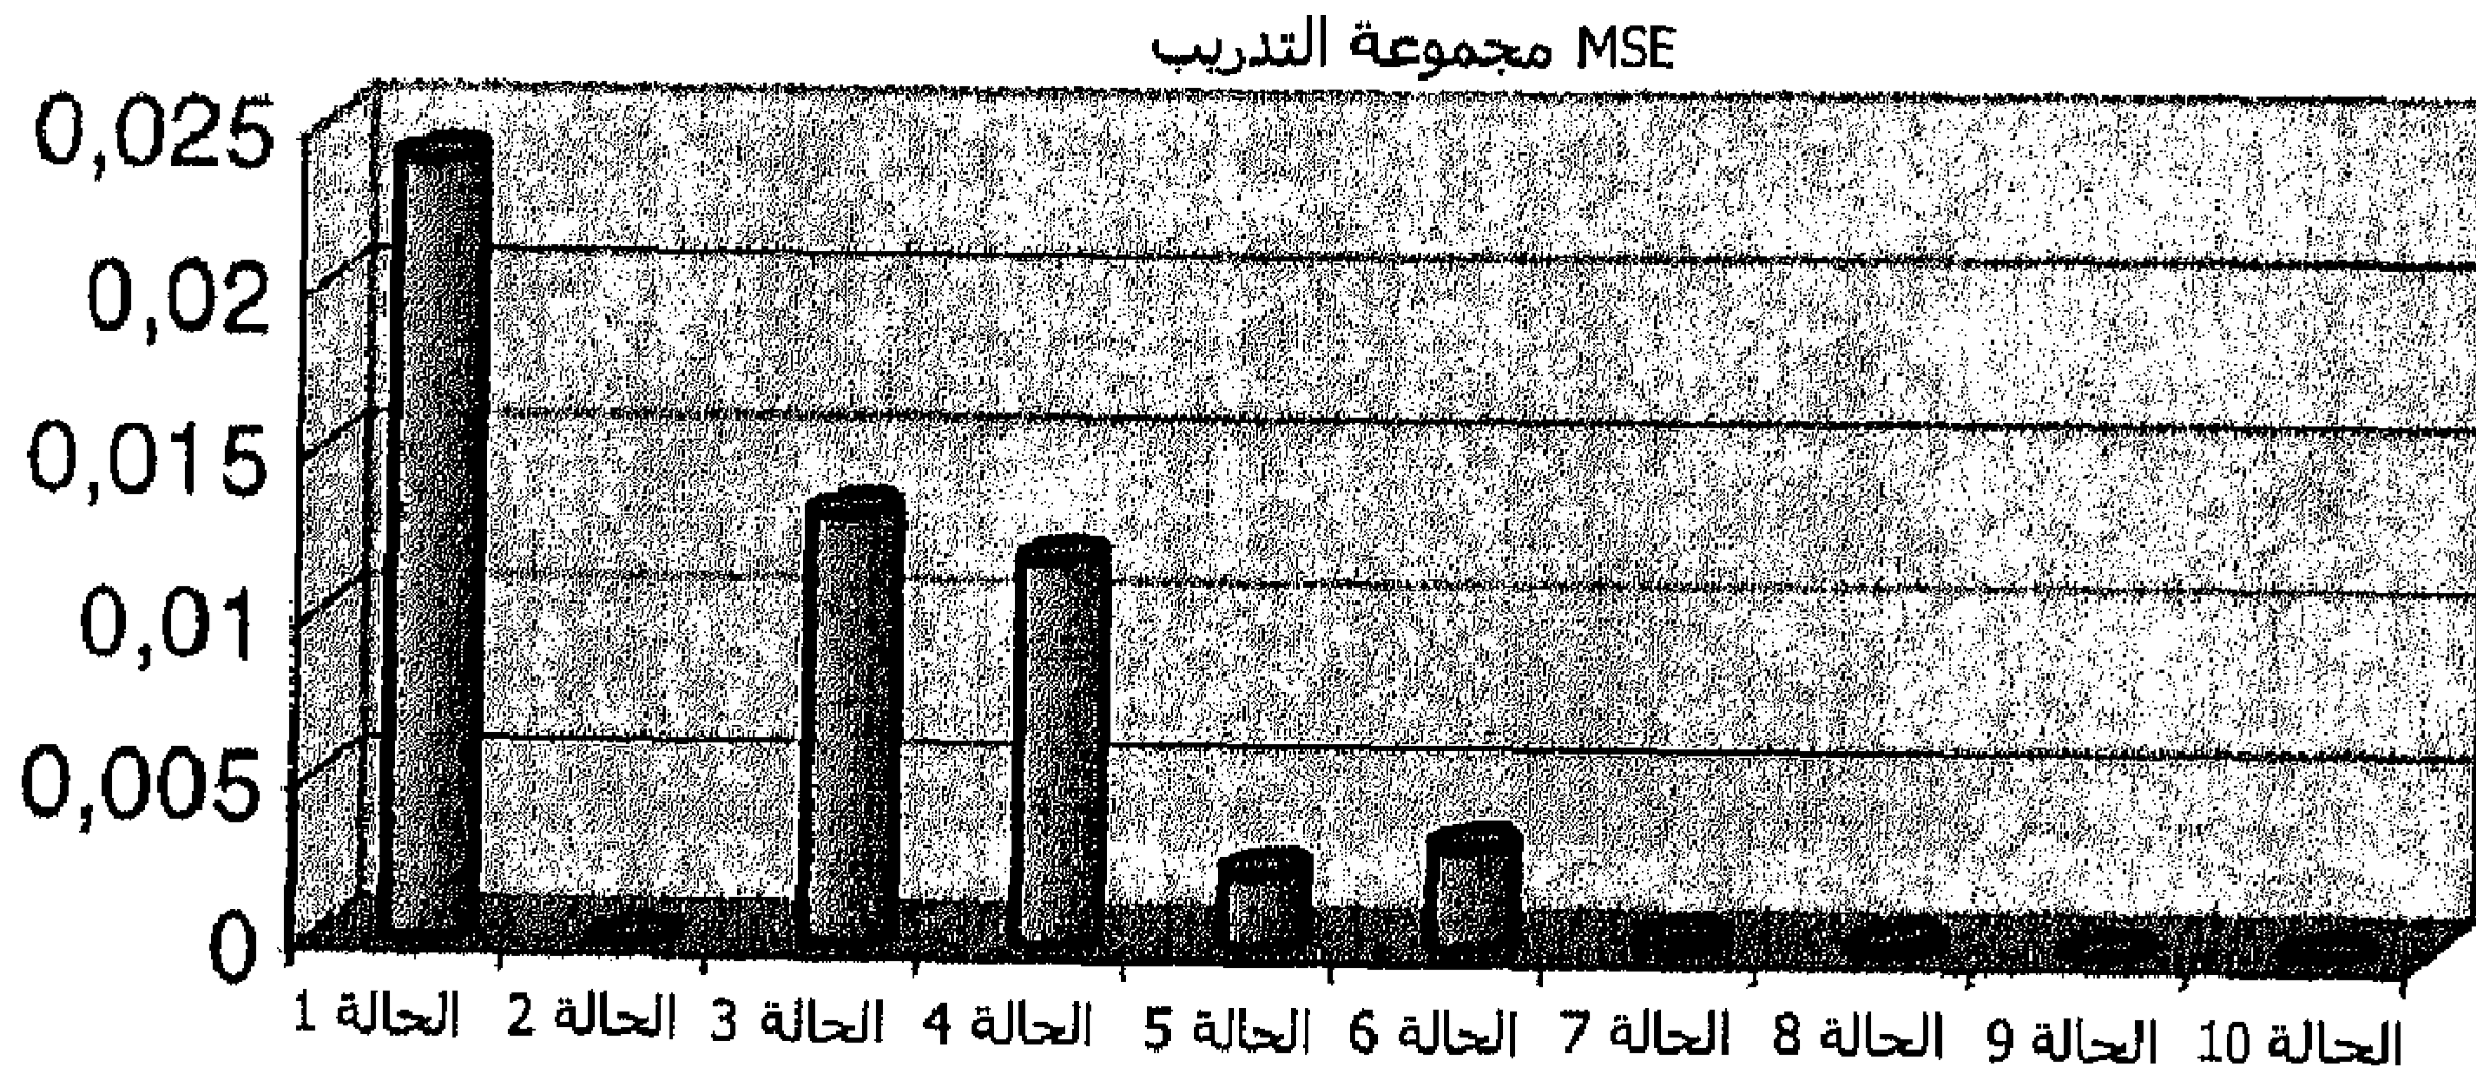


يشير MSE إلى الانحراف العام لمجموعة المتوقعات بالنسبة لقيمتها الحقيقية. في (الشكل 13)، يمكننا ملاحظة أن الخطأ مشابه، أو أقل منه للأنظمة المُختبرة سابقاً. إن خطأ الحالة 1 أعلى بشكل واضح، وهو مشابه لخطأ الشبكات العصبونية. وعندما يصبح النظام أكثر تعقيداً، تزداد قدرته على ضبط بارامترات التدريب بطريقة ما، بحيث يكون عدد الأخطاء أصغرياً.

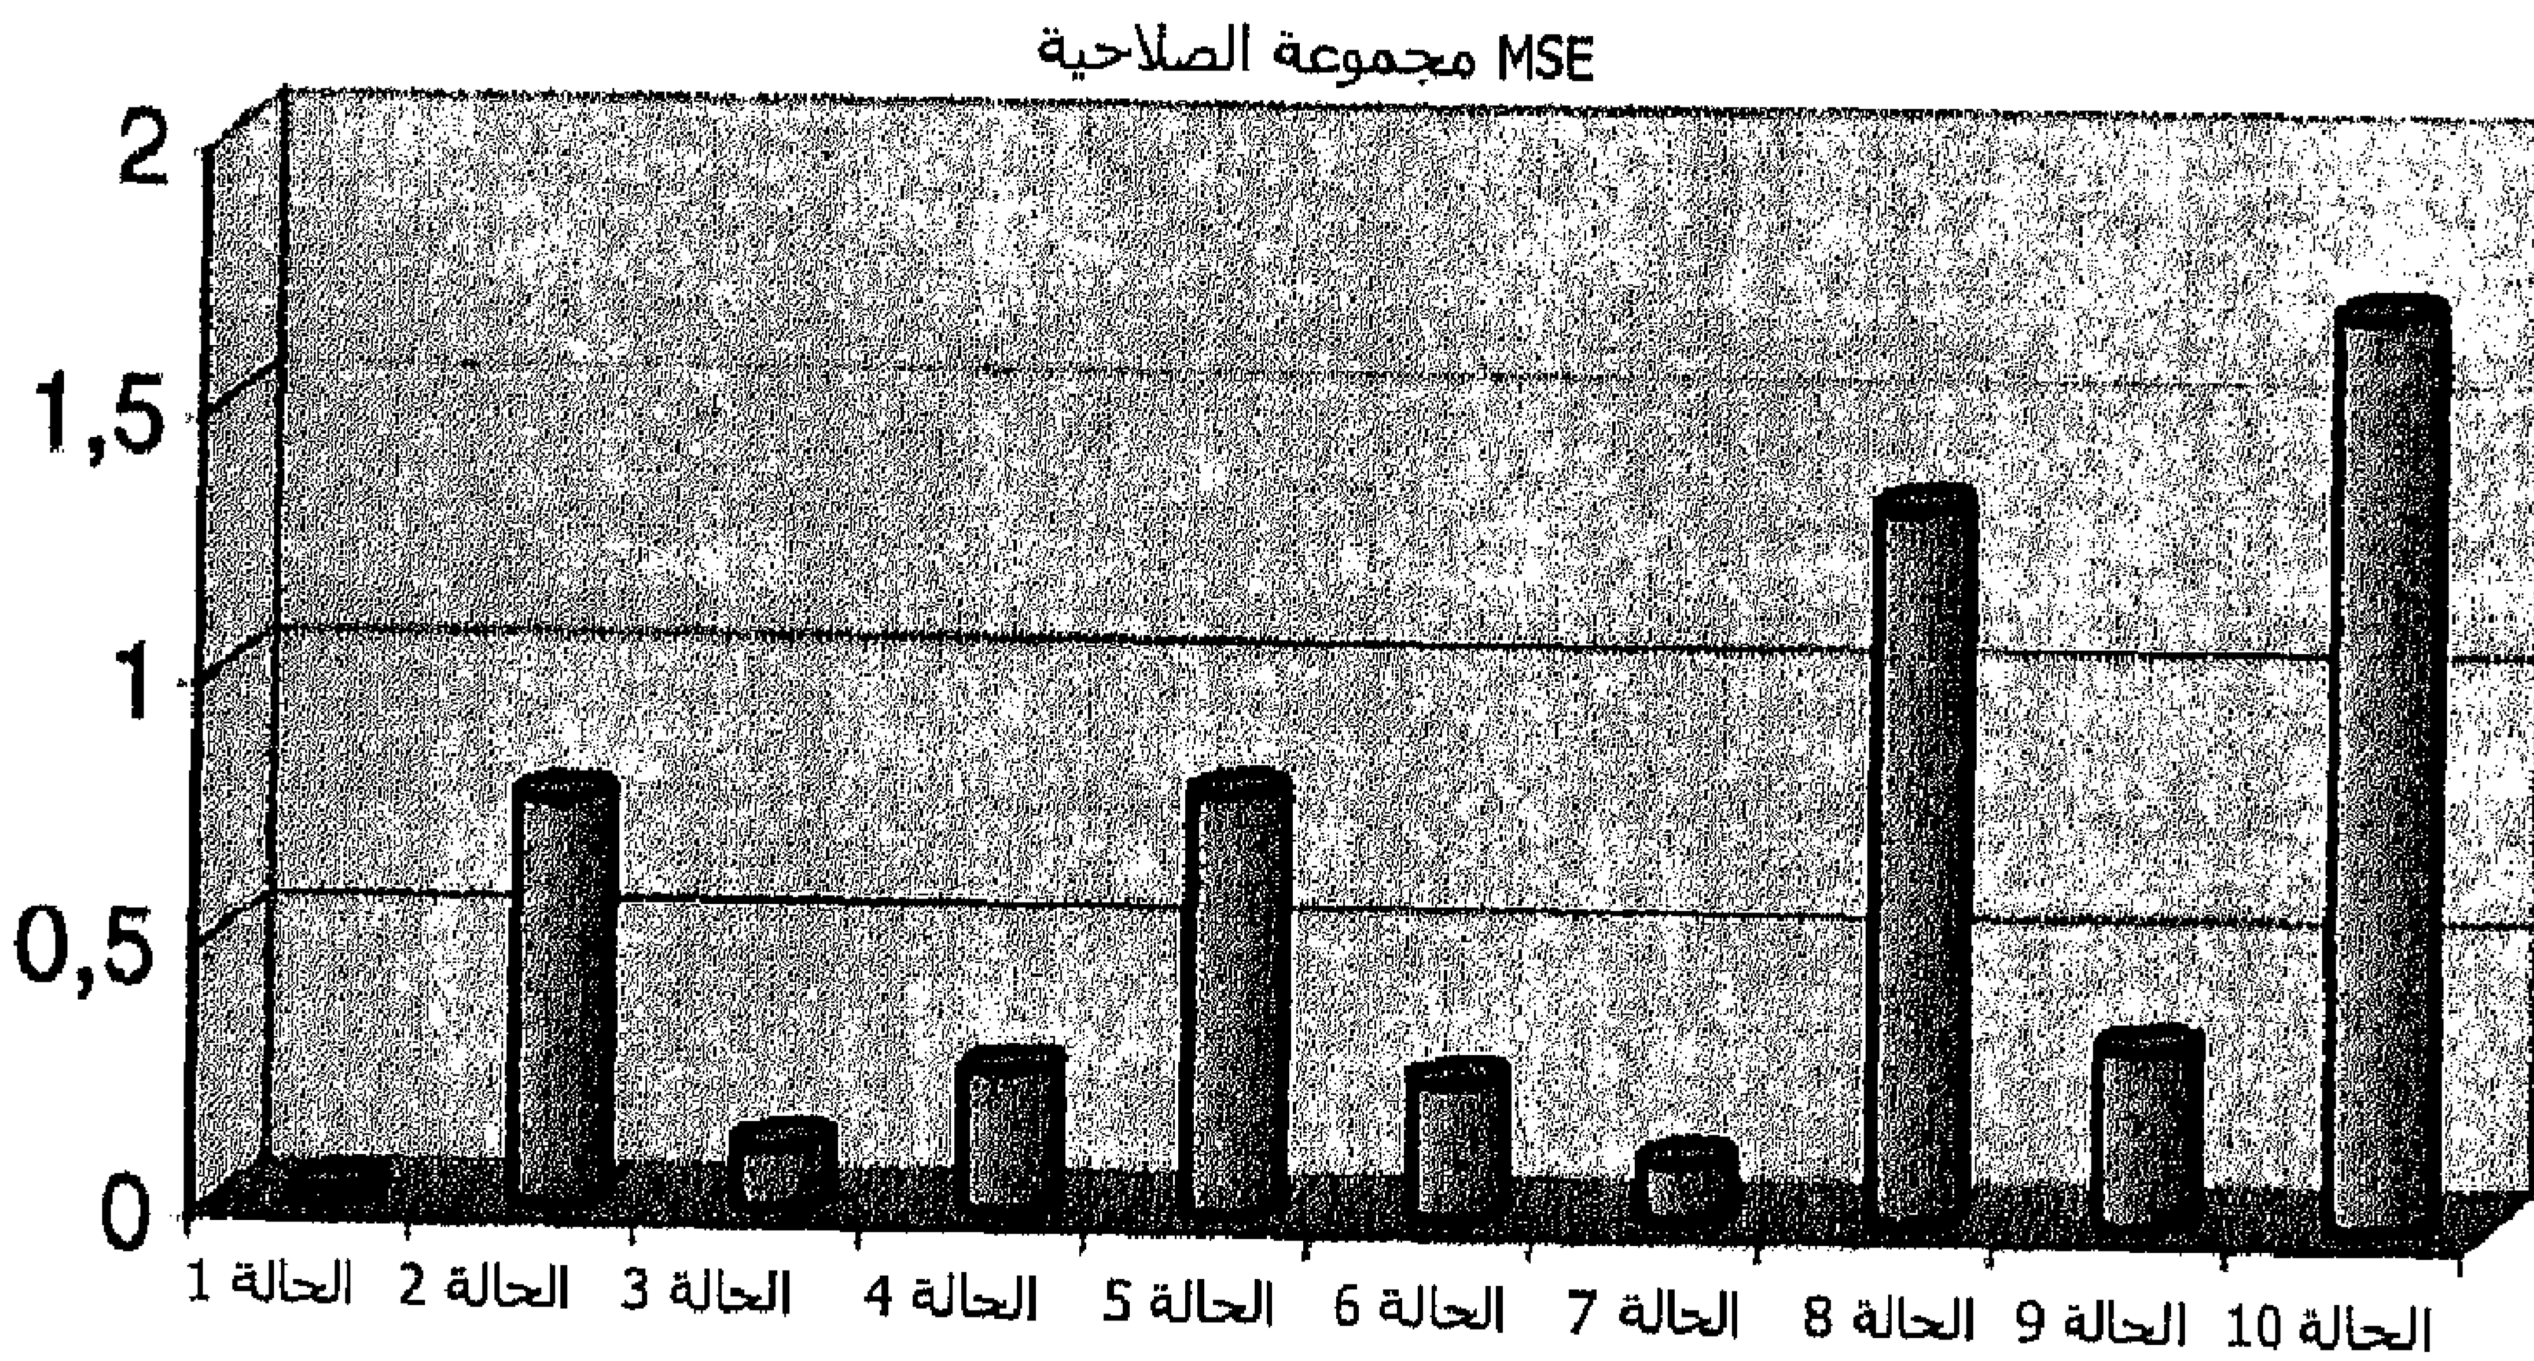
لاختبار قدرة التعلم لهذه الأنظمة ومقارنتها بالشبكات المُختبرة سابقاً، يجب علينا أن ندقق سلوك مجموعة الصلاحية. فأي نظام بقدرة تعميم جيدة سيمتلك MSE جيدة في مجموعة

الصلاحية، وMSE مقبول من أجل أنماط التدريب. يمكن أن نستنتج من (الشكل 14)، بأن الحالة 1 هي فقط النظام ANFIS بخطأ مشابه لمثيله للشبكات العصبونية. في كافة الحالات، يزداد الخطأ بشكل ملحوظ. وهذا يثبت حقيقة، أن معدل النجاح العالي أو MSE في مجموعة التدريب لا يضمن تعلماً جيداً وذلك حالة واضحة للتدريب المفرط (أكثر من اللازم).

الشكل (13) *مقارنة MSE في مجموعة التدريب. في كافة الحالات تساوت أو تحسنت نتائج الشبكات العصبونية*



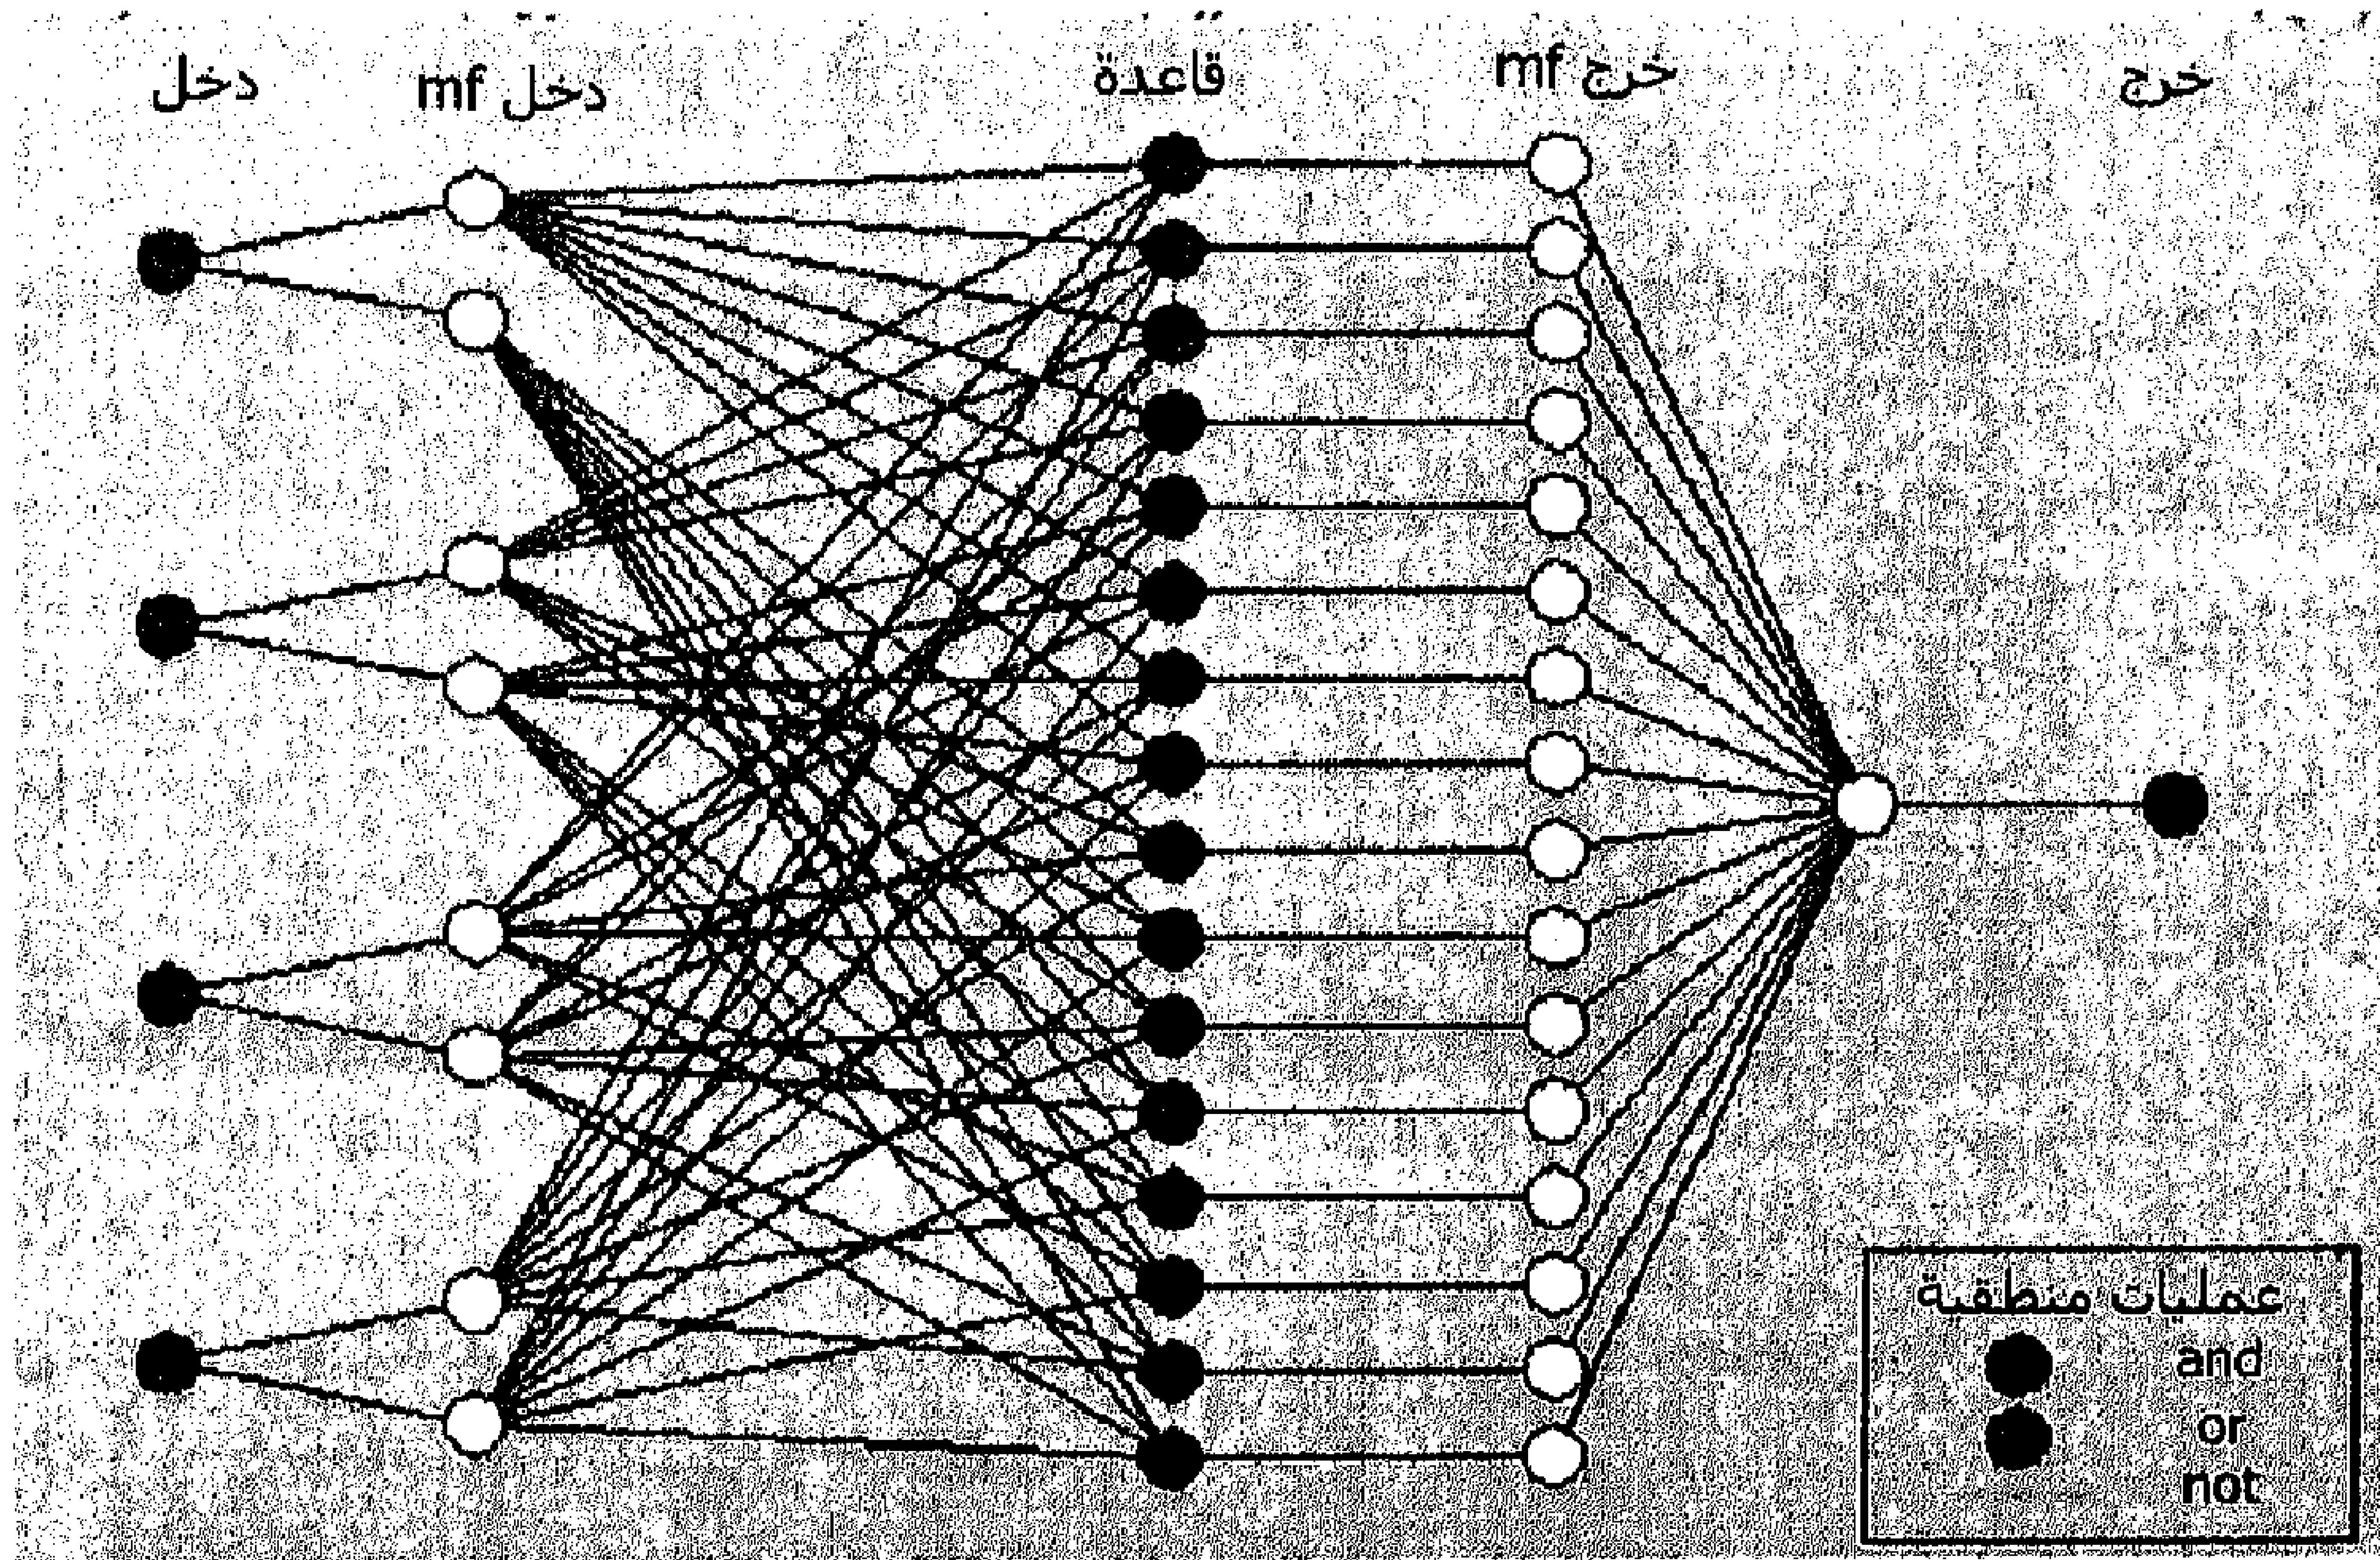
الشكل (14) *مقارنة MSE في مجموعة الصلاحية. فقط في الحالة 1 يكون MSE من نفس مرتبة MSE المُكتسب بالشبكات العصبونية.*



يمكننا إيجاز النتائج المكتسبة بذكر أن النظام ذا قدرة التعميم الأفضل هو الحالة 1، وسيعطي القسم القادم تفاصيل أكثر على طبولوجيته.

يمثل (الشكل 15) المواصفات والطبقات الخفية لنظامنا ANFIS من الطراز 3 من المرتبة 0، بتابعين نموذجيين لكل متغير دخل. بالمقارنة مع الأنظمة المدروسة الأخرى، فهو سهل ويقدم قدرة تعلم أكثر.

الشكل (15) *طبولوجية النظام ANFIS للحالة 1. من أجل كل متغير يوجد تابعان مميزان فقط (توابع عضوية أو MF)*



إن قواعد حساب معطيات الخرج منفذة على (الشكل 16). الذي يبين كيف تعطي كل قاعدة خرجاً معيناً. إن ANFIS المقترح، الذي يرتب أربعة متغيرات دخل بتابعين (درجة عصبونية لكل واحد)، يمكنه إنتاج ما مجموعه 16 قاعدة مختلفة. بعد تعويم المدخلات، وتنفيذ العمليات الموافقة، يفك تعويم النتيجة بواسطة مجموع مُثقل متوسط.

يُعدّل التعلم بارامترات توابع غاوس العضوية المميزة، كما يلاحظ في الخطوط البيانية على (الشكل 17).

نتائج الخوارزمية: مناقشة

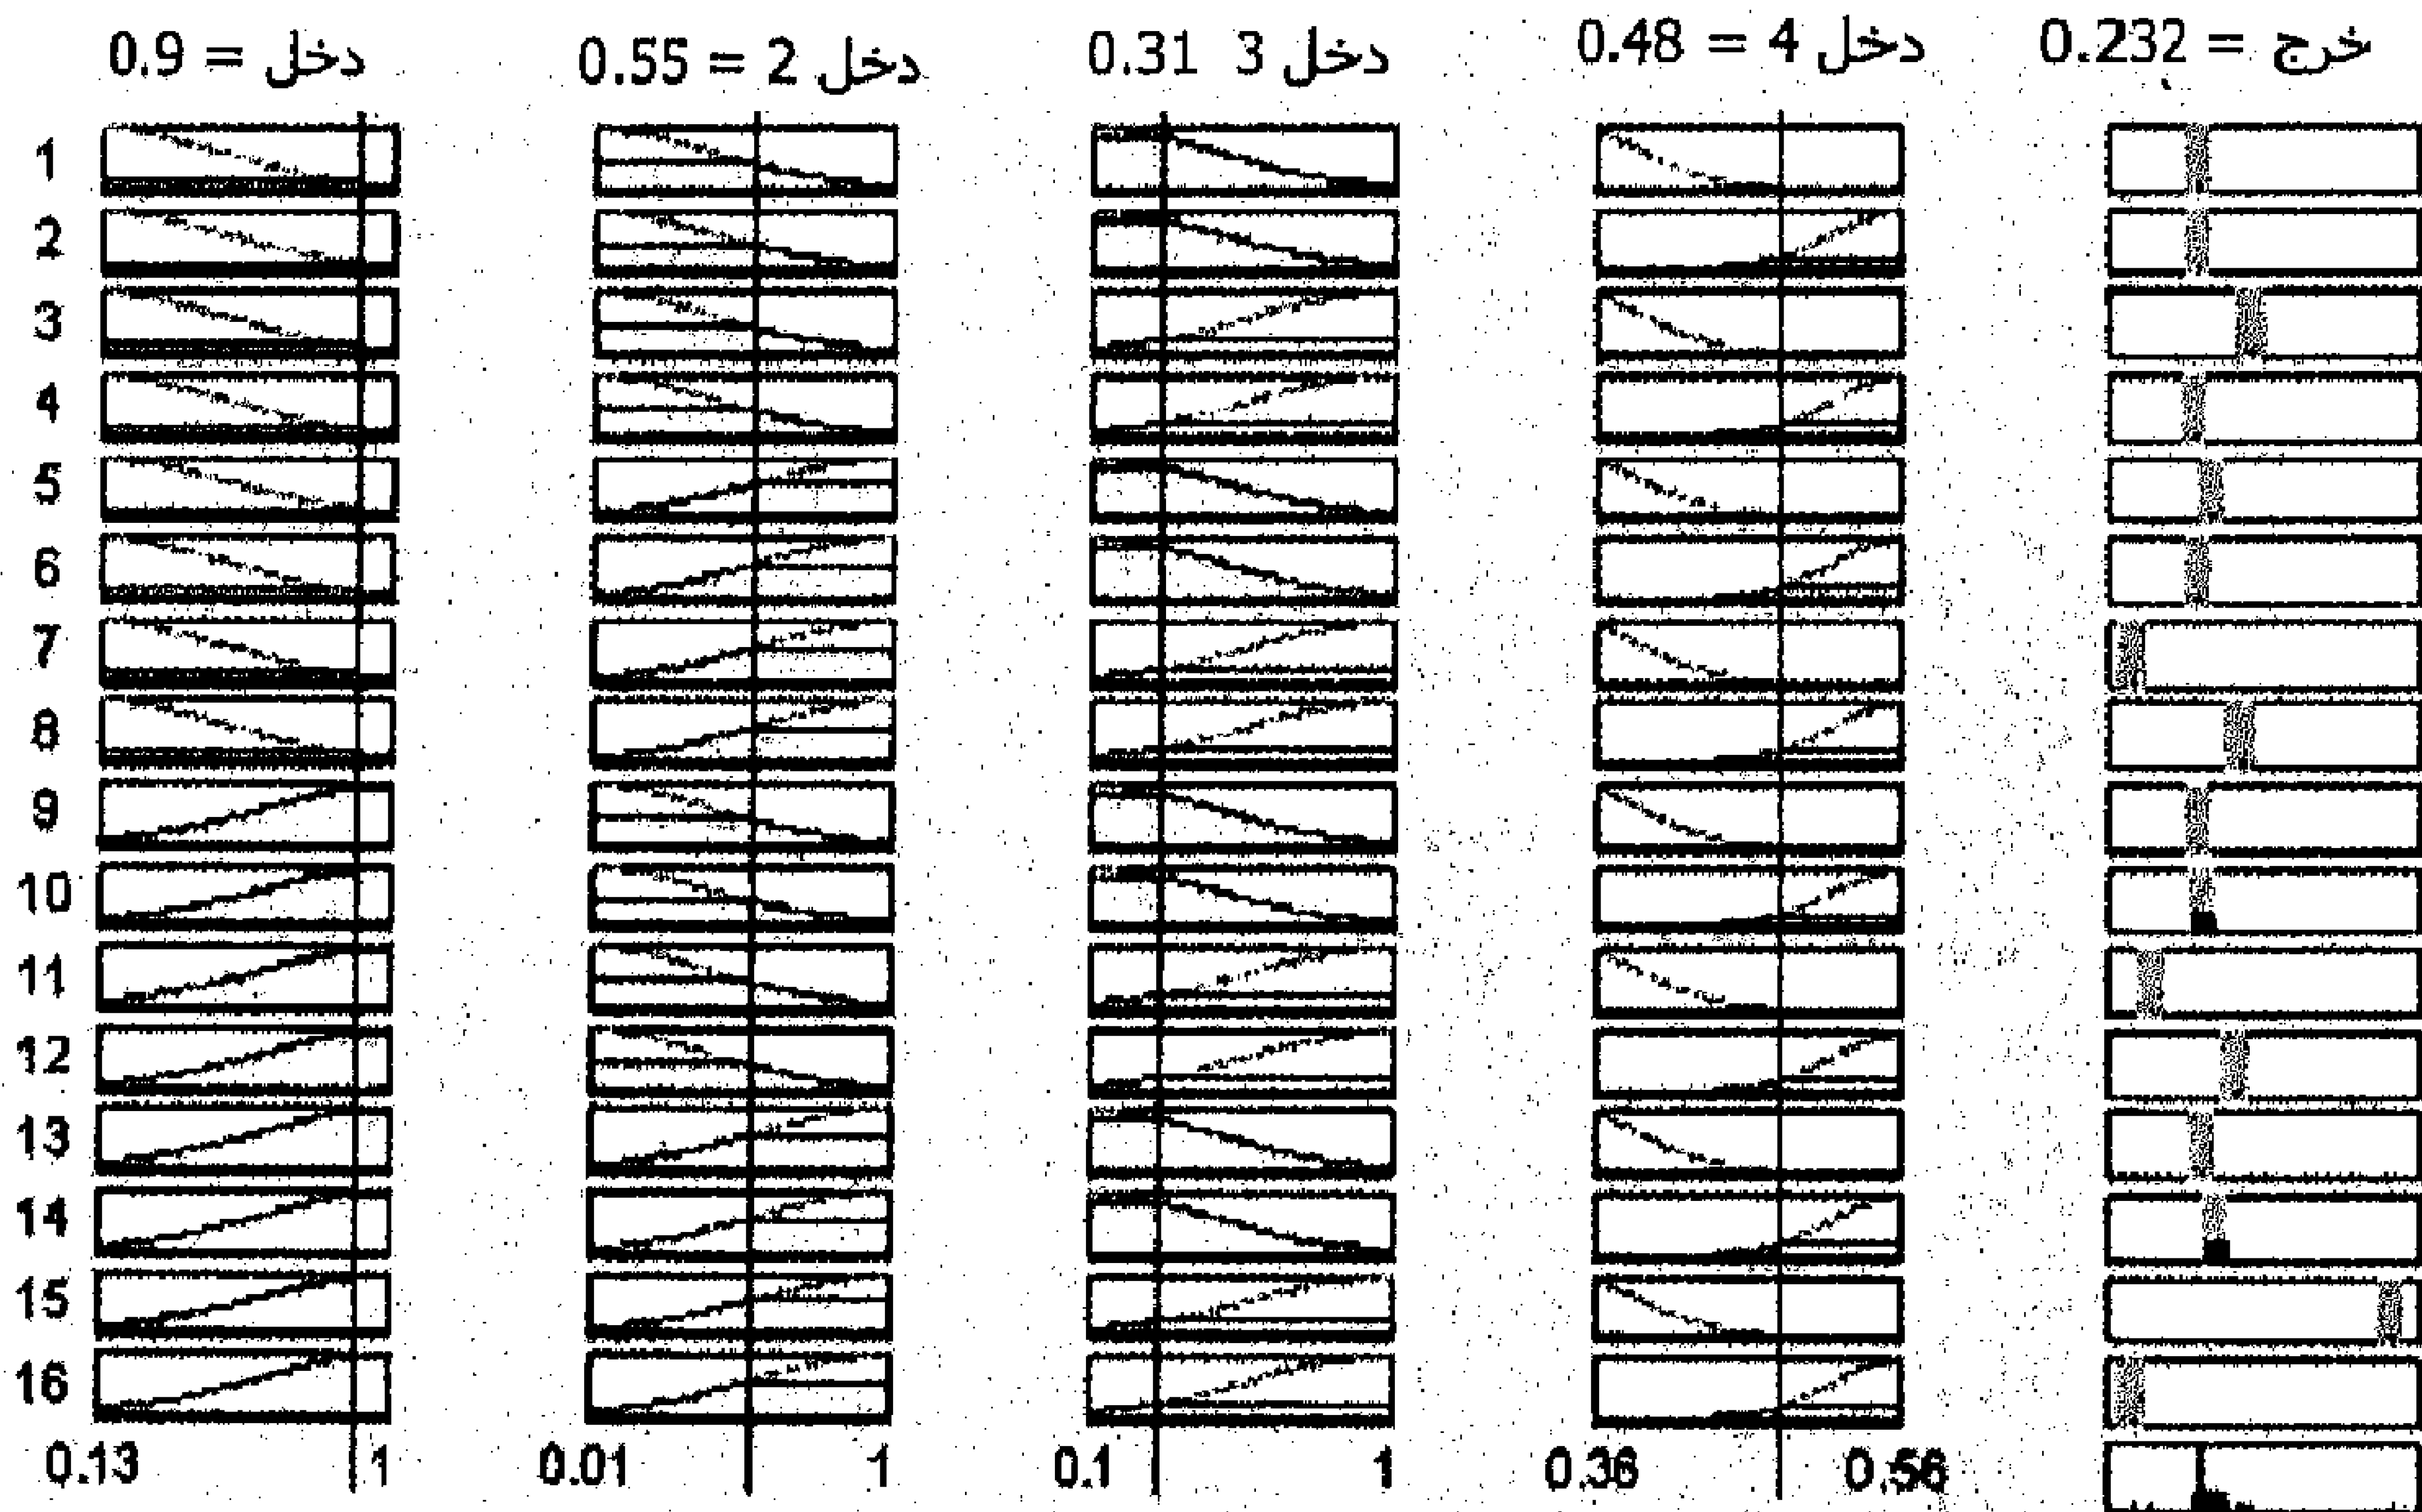
مسألة التدريب المفرط

يمكن أن تكون الخوارزمية المدروسة متنبأً جيداً، فقط إذا كان لمجموعة الصلاحية والتدريب خطأ صغير. إذا كان خطأ الصلاحية أكبر بكثير من خطأ التدريب، فعندها توجد مشكلة ما كالضبط

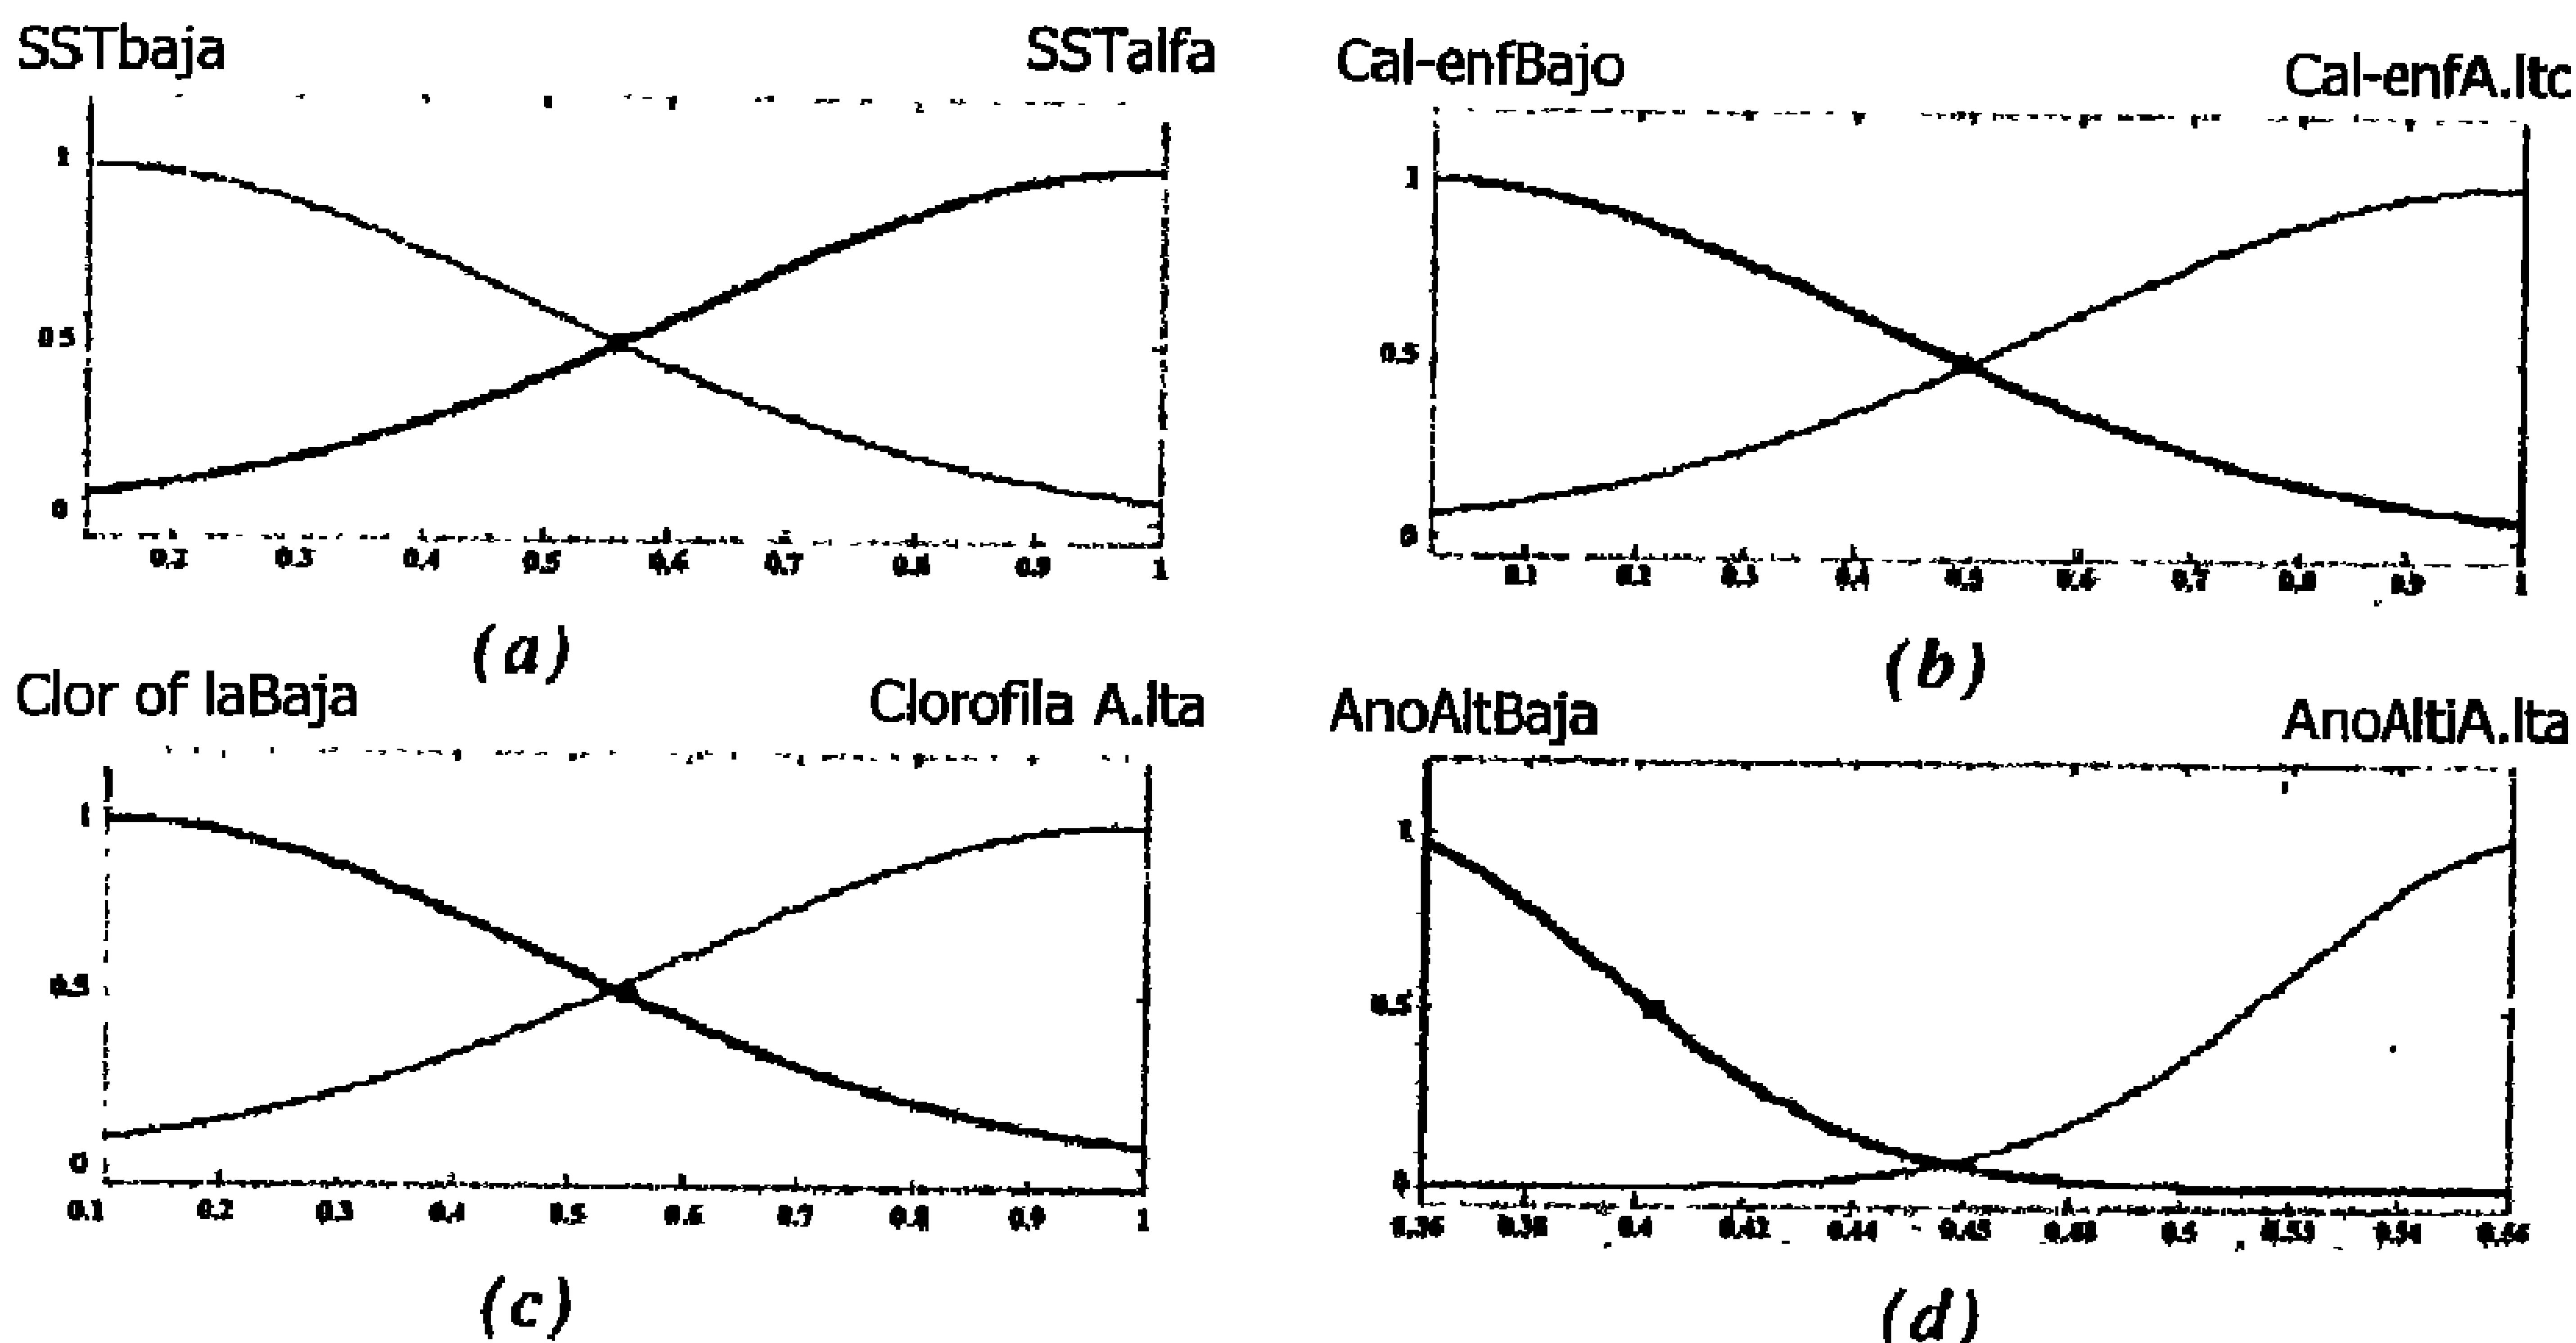
المفرط أو التدريب أكثر من اللازم من خلال الإحصائيات، من المعلوم جيداً أنه عندما نستخدم نموذجاً بعدة بارامترات لضبط مجموعة المعطيات، التي ترد من معالجة بحرية قليلة، فقد يكتشف النموذج المُكتسب الاتجاهات الحقيقية للمعالجة الأصلية، بالرغم من أنه قد يقدم خطأ ضبط معطيات صغير. في هذه الحالة، يُجبر التدريب على استيفاء (استكمال) المعطيات متضمناً الضجيج، بواسطة تابع سيغمويد معقد.

نوضح هذه المسألة بالمثال التالي. يمر الخط البياني في (الشكل 18a) عبر نقاط التدرب (الممثلة بالنقط السوداء). وهو استيفاء كثير حدود من الدرجة السابعة لثمان نقط معطية، وبالتالي يكون النموذج بأخطاء صفرية. على أية حال، إذا اعتبرنا مجموعة بديلة من معطيات التحكم، فإنه لا يمكن لنفس الخط البياني أن يتوقع المعطيات الجديدة بدقة - كما هو الحال في (الشكل 18b)، بسبب الكمية المفرطة من البارامترات المطبقة (ثماني معاملات لكثير الحدود). يمكن الحصول على نموذج أكثر واقعية باعتبار عدد قليل من البارامترات (على سبيل المثال، كثير حدود من الدرجة الثالثة للشكل 18c). في تلك الحالة، يكون خطأ التقريب مماثلاً لمعطيات التدريب ومجموعات معطيات الصلاحية، ويشير إلى أن الاتجاهات الحقيقية للنموذج قد اُكتسبت. يبين (الشكل 18d). الاختلاف بين كلا النموذجين.

الشكل (16) *سلوك النظام عندما تُقدم عينة الدخل التالية: SST = 0.9، الشذوذ الحراري = 0.55، اليخضور = 0.31، الشذوذ الارتفاعي = 0.48، وتوقع النظام هو 0.232، أما الخرج الحقيقي فهو 0.22، وبالتالي يمكن اعتباره ناجحاً.*

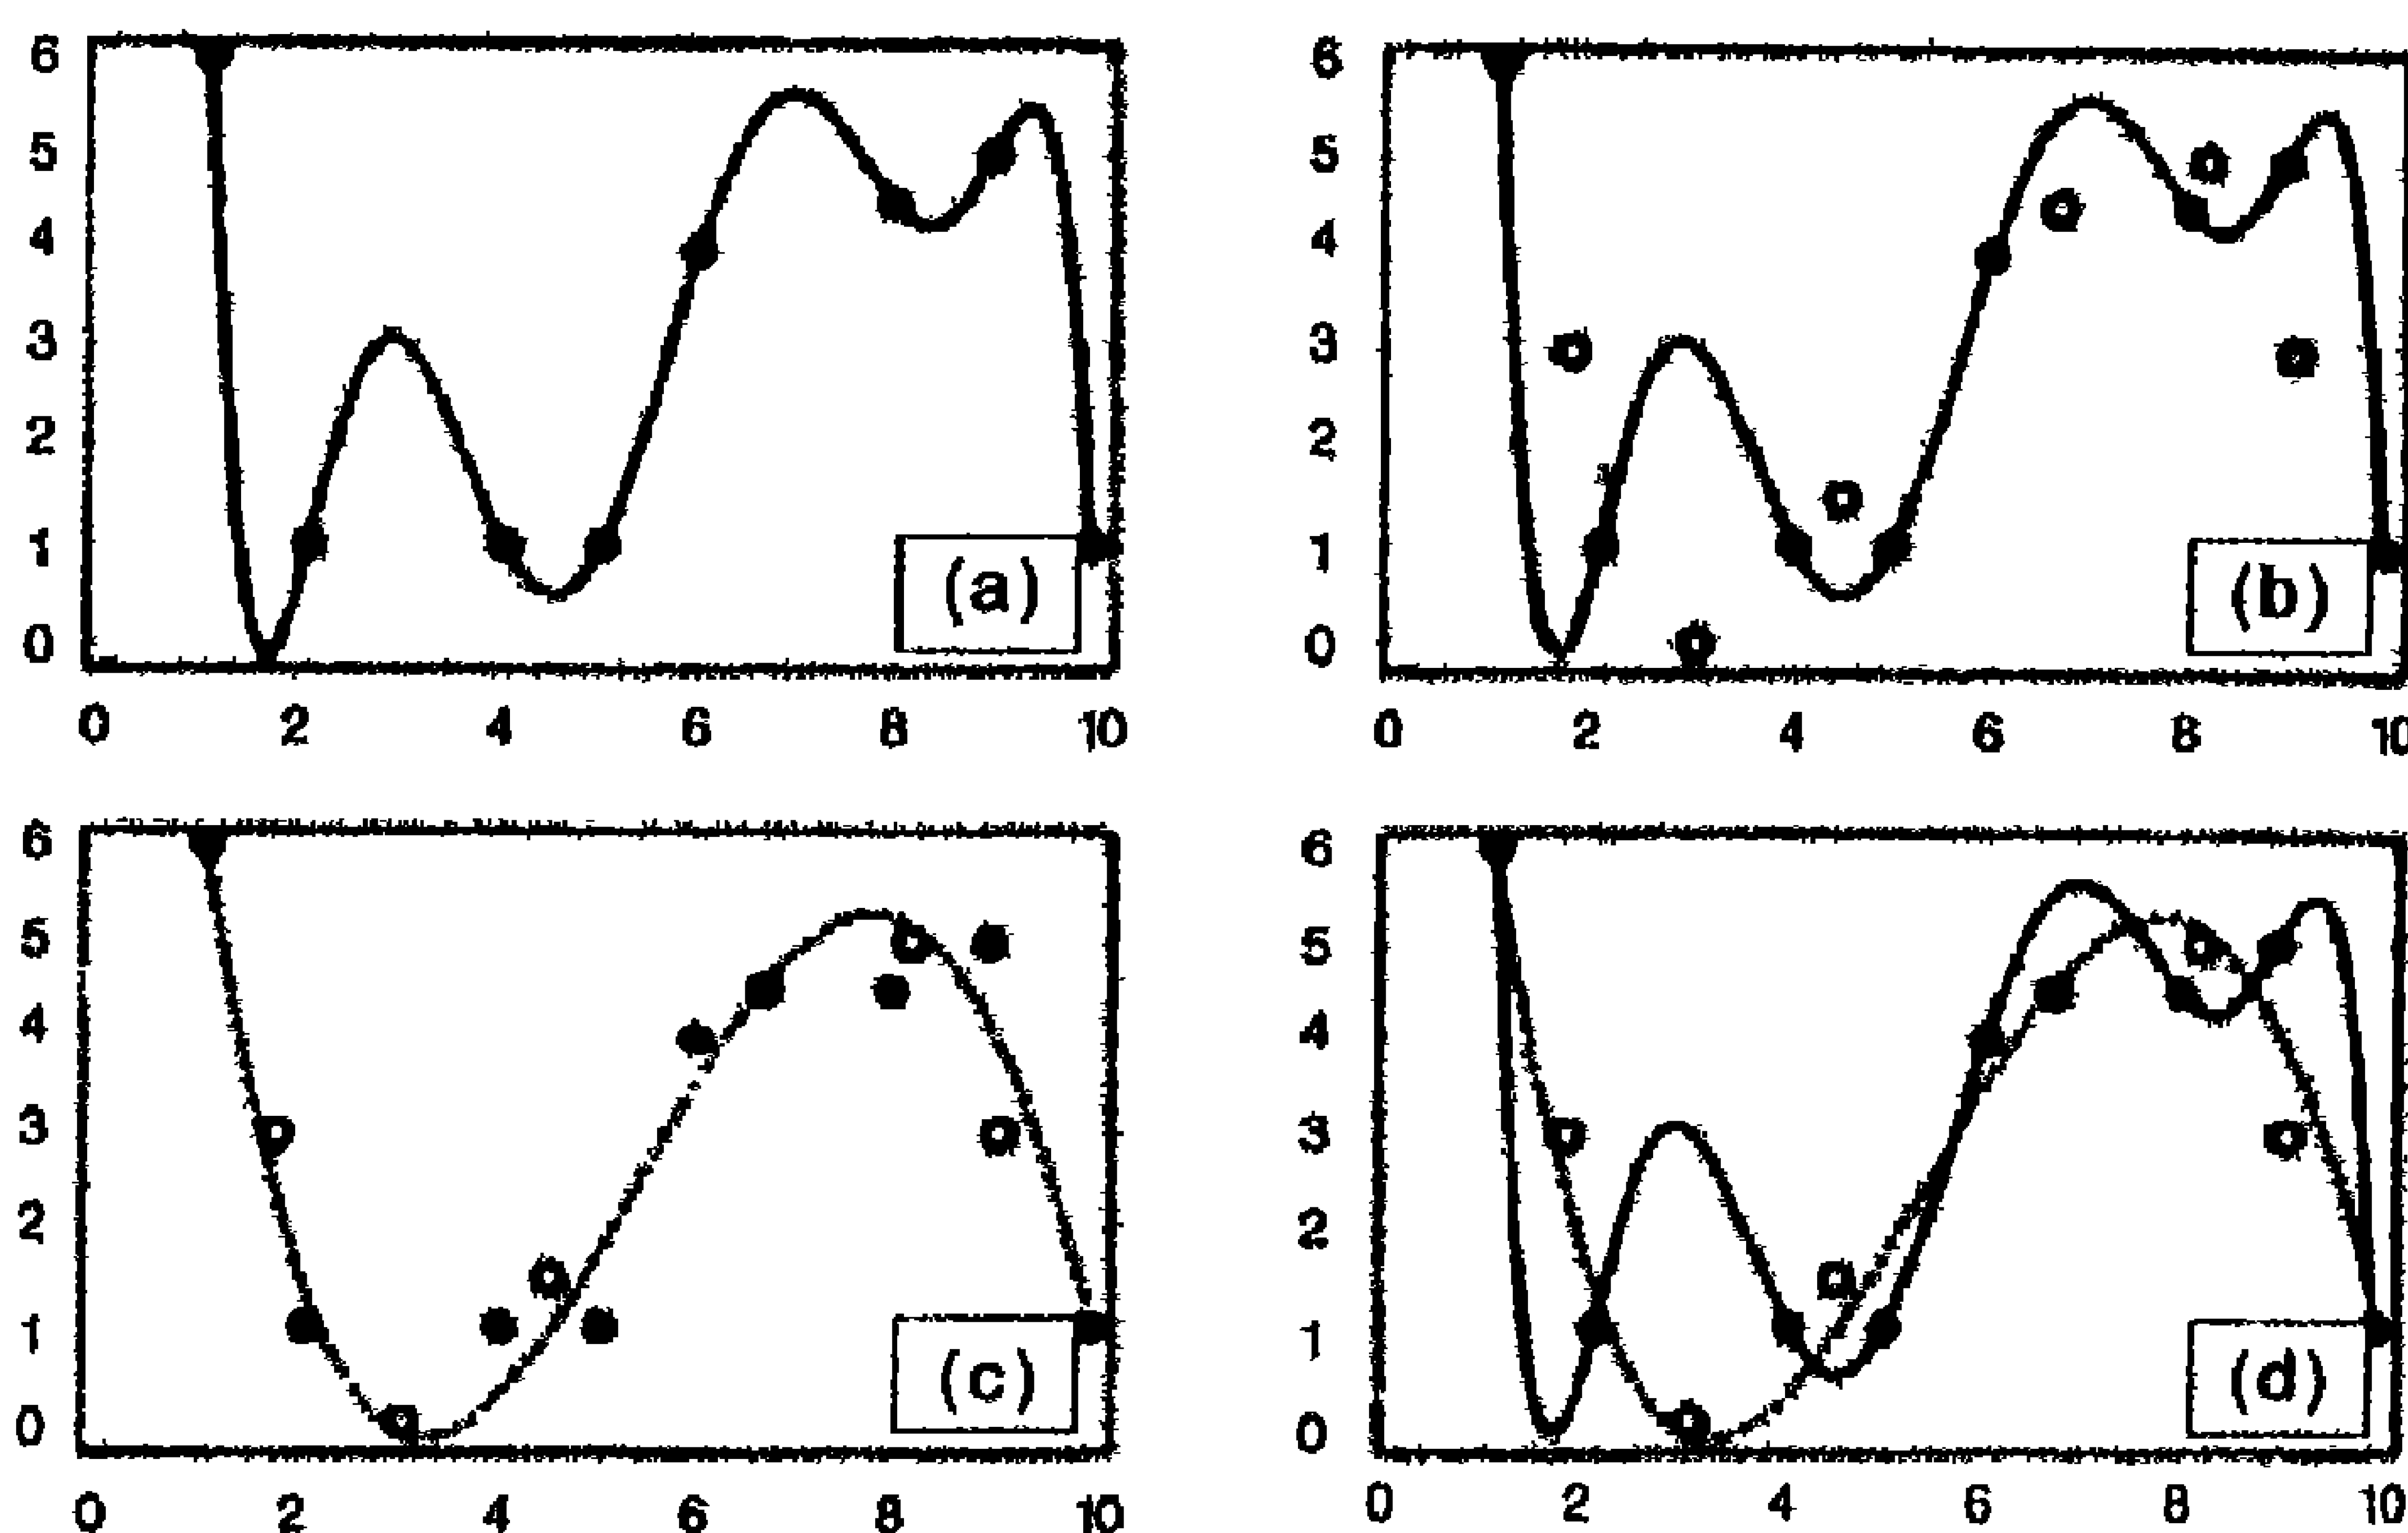


الشكل (17) *توابع درجة عضوية بعد التدريب. a - SST، b - شذوذ حراري c - تركيز اليخضور، d - شذوذ ارتفاعي*



يعكس (الشكل 17d) تغيرات التابعين وفقاً لتعديلات بارامترات غاوس. تغييرات توابع غاوس البقية هي أقل أهميةً.

الشكل (18) *مثال على التدريب المفرط. a ـ نموذج ببارامترات عديدة جداً لضبط المعطيات. b ـ خطأ كبير في معطيات التحكم. c ـ نموذج ببارامترات أقل يُقرّب نفس الأسلوب معطيات التدريب ومعطيات الصلاحية. d ـ مقارنة كلا النموذجين (مُكيّف من Castillo et al. 1999).*



يظهر تحليل (الأشكال 10 و13 و14) أن هذه المشكلة متكررة. يمثل (الشكل 10) MSE لمجموعات التدريب والصلاحية للشبكة التابعية بقواعد توابع مختلفة ثلاث. عندما ينخفض MSE التدريب، يزداد MSE الصلاحية بشكل كبير جداً باستثناء الحالة 1، حيث تصل كلا القيمتين بشكل آني إلى حصص الاهتمام النسبية، وتتطابق بدقة مع القاعدة الأبسط (أي القاعدة التي تمتلك توابع أقل وبارامترات أقل للضبط).

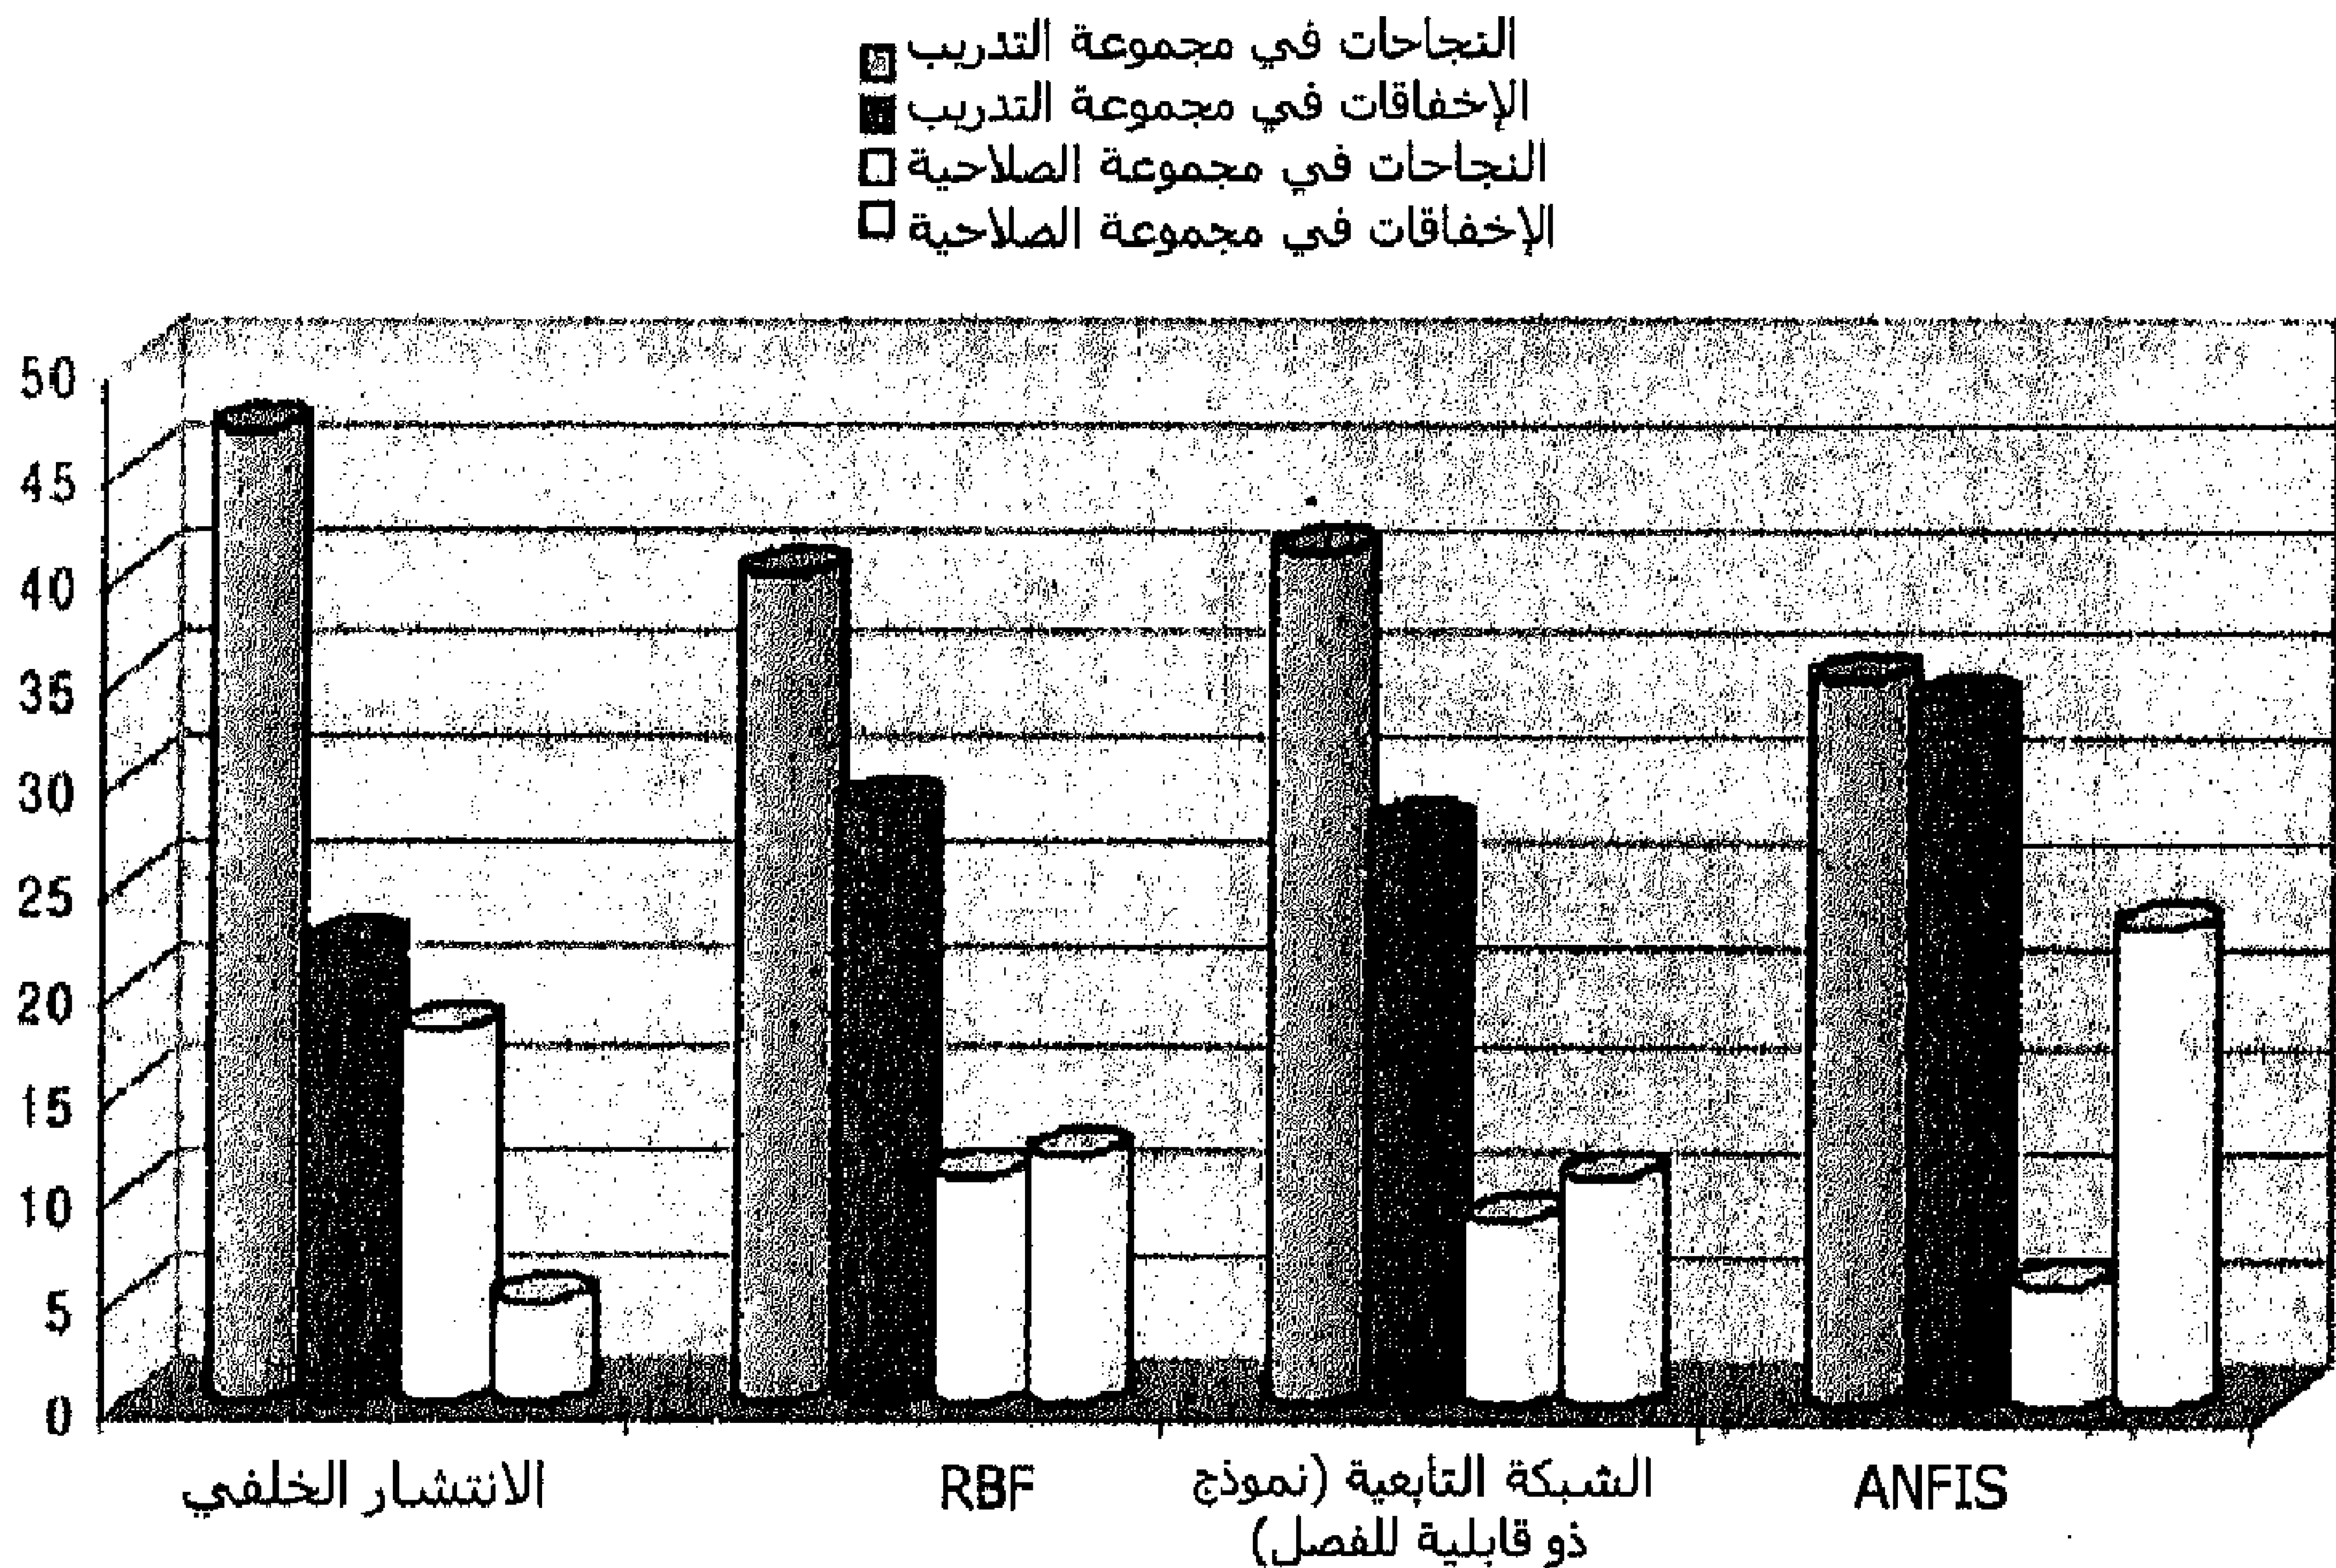
يقارن (الشكلان 13 و14) عدة بنى ANFIS. يزداد MSE لأنماط الصلاحية إلى حد كبير (الشكل 14)، عندما ينخفض MSE لأنماط التدريب (الشكل 13). باستثناء الحالة 1، حيث تكون الأخطاء مشابهة لتلك الخاصة بالشبكات العصبونية، بتخمين الأنماط لمجموعة الصلاحية والتدريب. الحالة 1 هي حالة البنية الأبسط والعدد الأصغر للبارامترات.

النتائج

قمنا بمقارنة النتائج الأفضل من الشبكات العصبونية المدربة، والشبكات التابعية، وANFIS متجنبين كافة الحالات التي قدمت ضبطاً مفرطاً.

يمكن أن يكون أول معيار في الاختيار لأحد الخوارزميات المُختبرة الأربعة هو عدد النجاحات والإخفاقات. يبين (الشكل 19) مستوى النجاحات والإخفاقات في مجموعات الصلاحية والتدريب.

الشكل (19) *مقارنة النجاحات والإخفاقات في مجموعات الصلاحية والتدريب للخوارزميات الأربعة.*

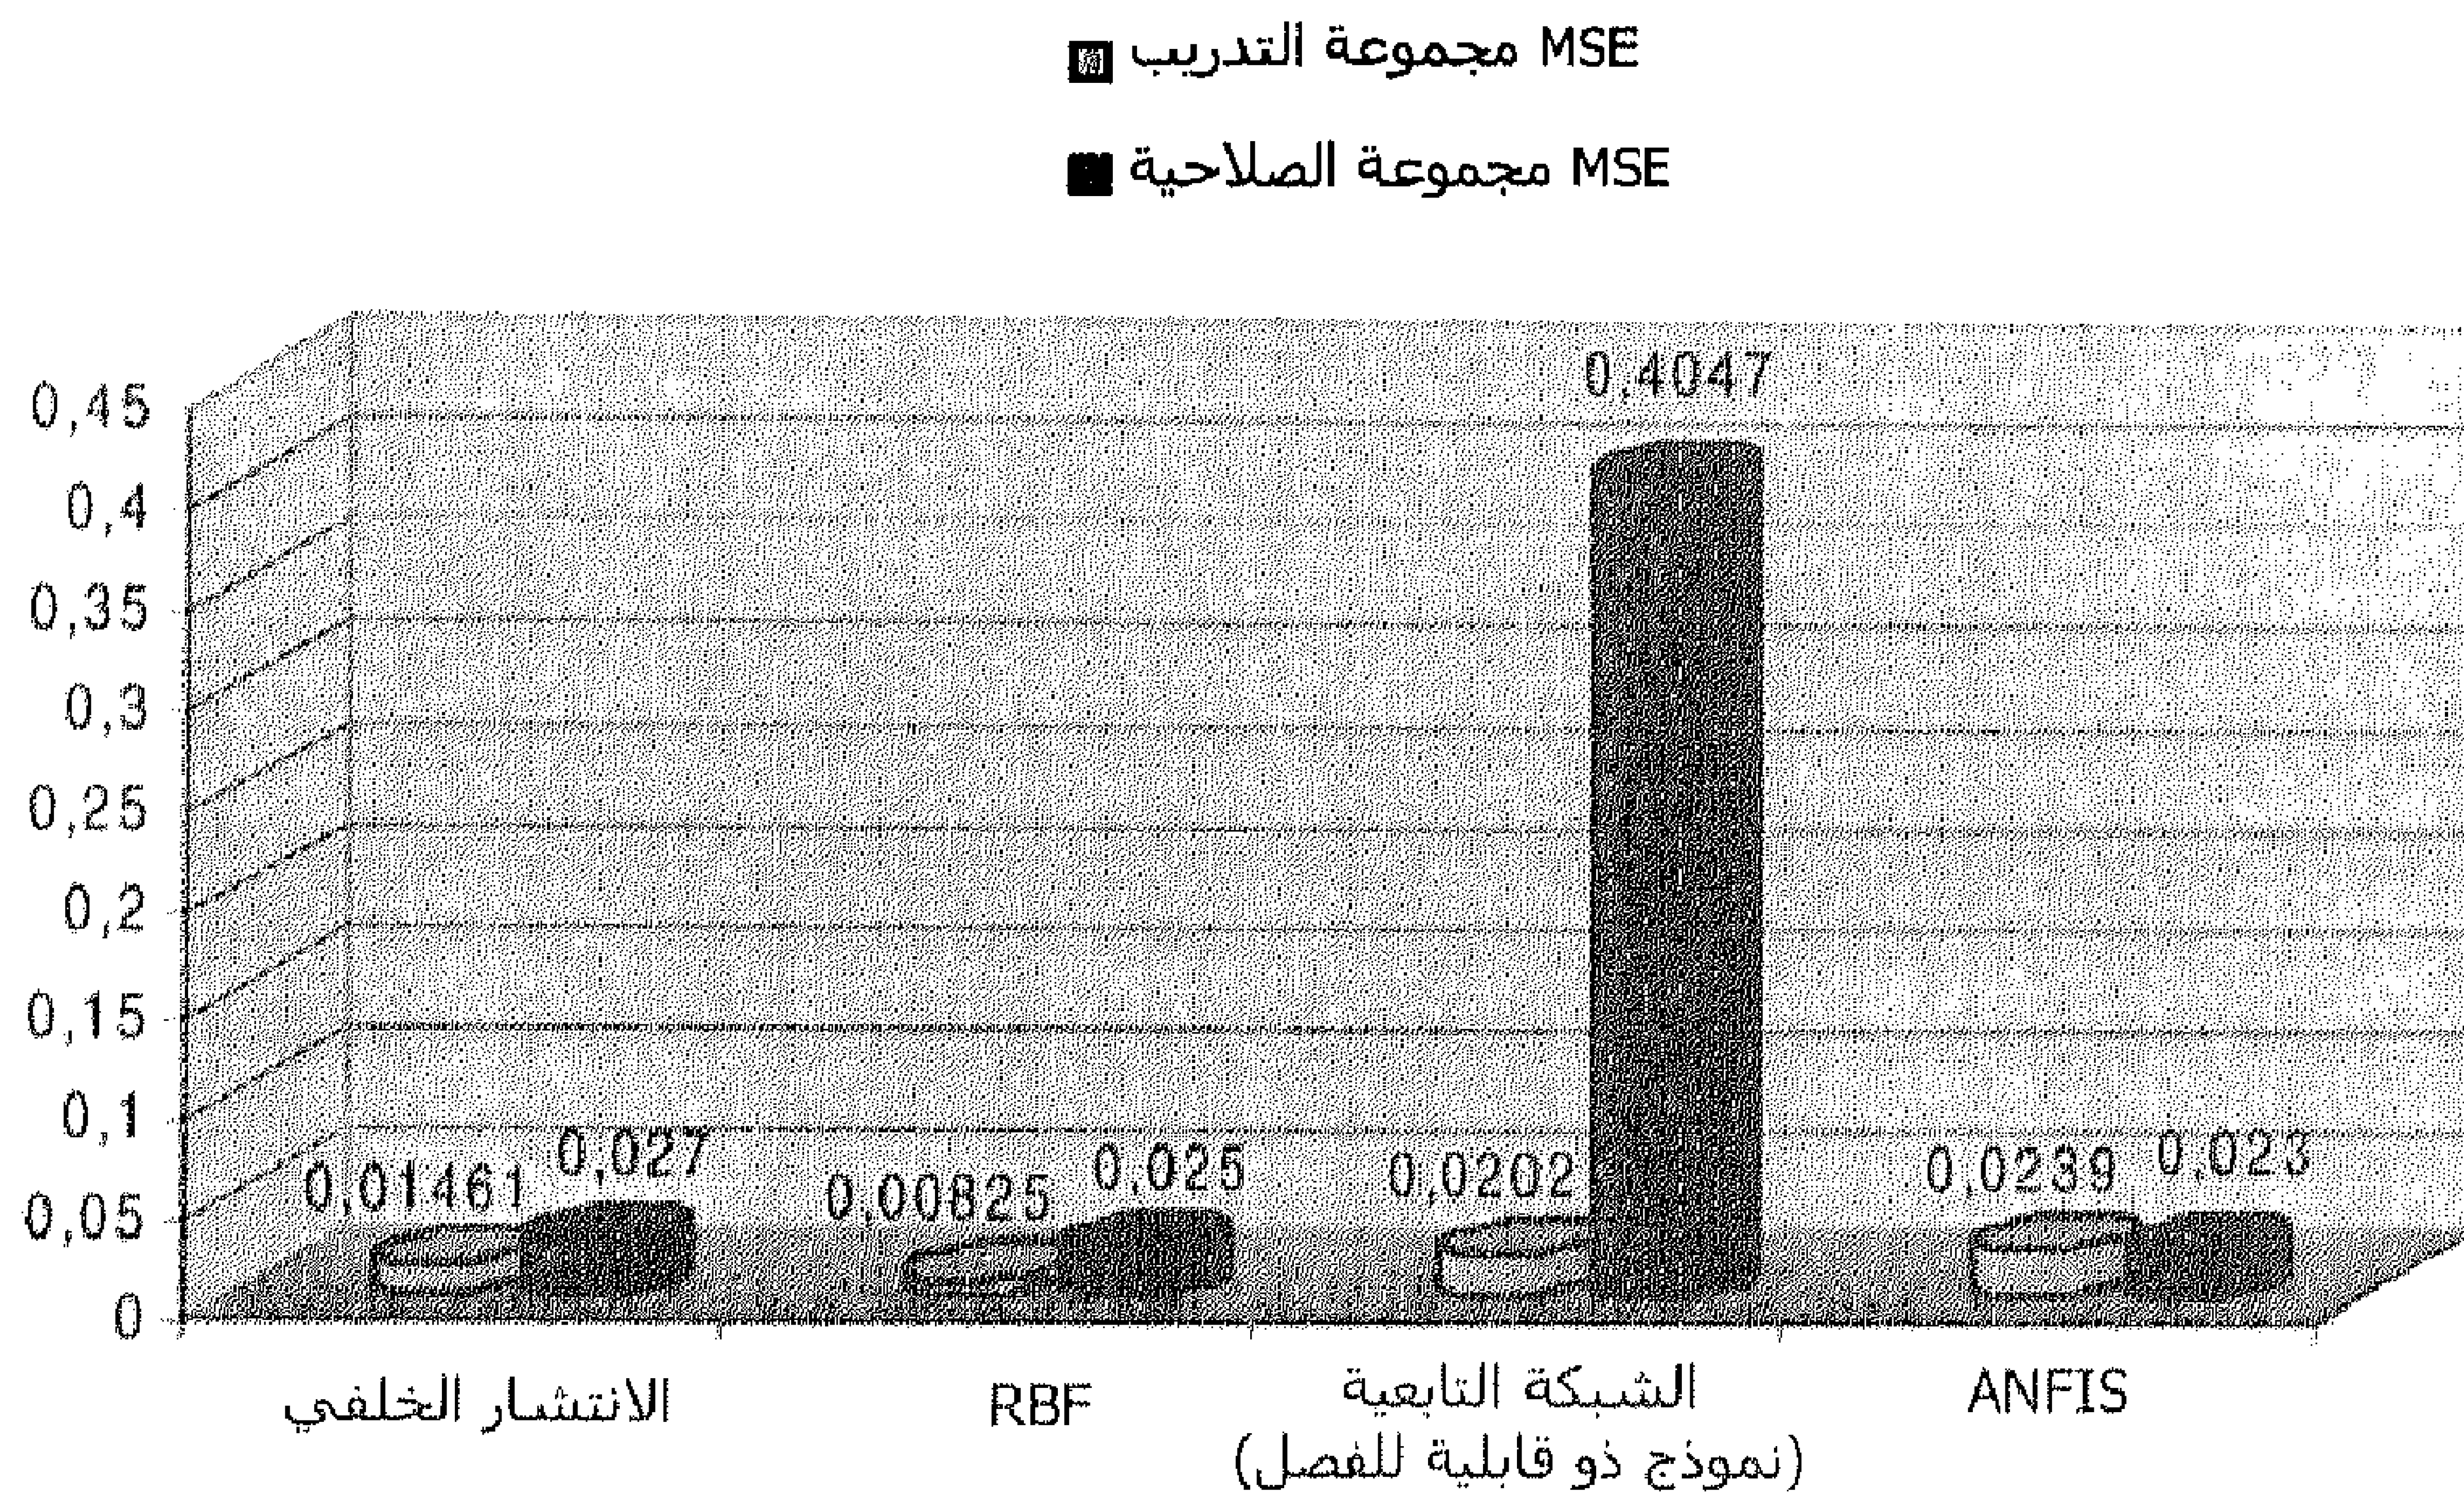


تقابل النتائج الأفضل بوضوح شبكة Perceptron متعددة الطبقات مُدربة بخوارزمية انتشار خلفي للخطأ، ولكن علينا أن نؤكد ذلك بتدقيق MSE لمجموعات التدريب والصلاحية انظر (الشكل 20).

الأخطاء في (الشكل 20) هي جميعها من نفس المرتبة باستثناء خطأ الصلاحية للشبكة التابعية، وهذا يعني في سياق مسألتنا، أن تكون قدرة التعميم لهذه الخوارزمية أصغر بسبب غياب النموذج الرياضي، الذي يوضح هذه المسألة.

أخيراً، اخترنا تطبيق شبكة Perceptron متعددة الطبقات مدربة بالانتشار الخلفي للخطأ، الذي يقدم ببساطة أكثر من ANFIS وشبكة RBF.

الشكل (20) *مقارنة MSE للخوارزميات المختلفة من أجل مجموعات الصلاحية والتدريب*



توليد خرائط احتمال صيد السمك

يُغذى النظام المقترح بصور من الأقمار الصناعية Orbview-2، وNOAA، وTopex-Poseidon. كما هو مذكور في الأقسام السابقة، فإن النتاجات المُشتقة من المعالجة هي خرائط بالمؤشرات التالية:

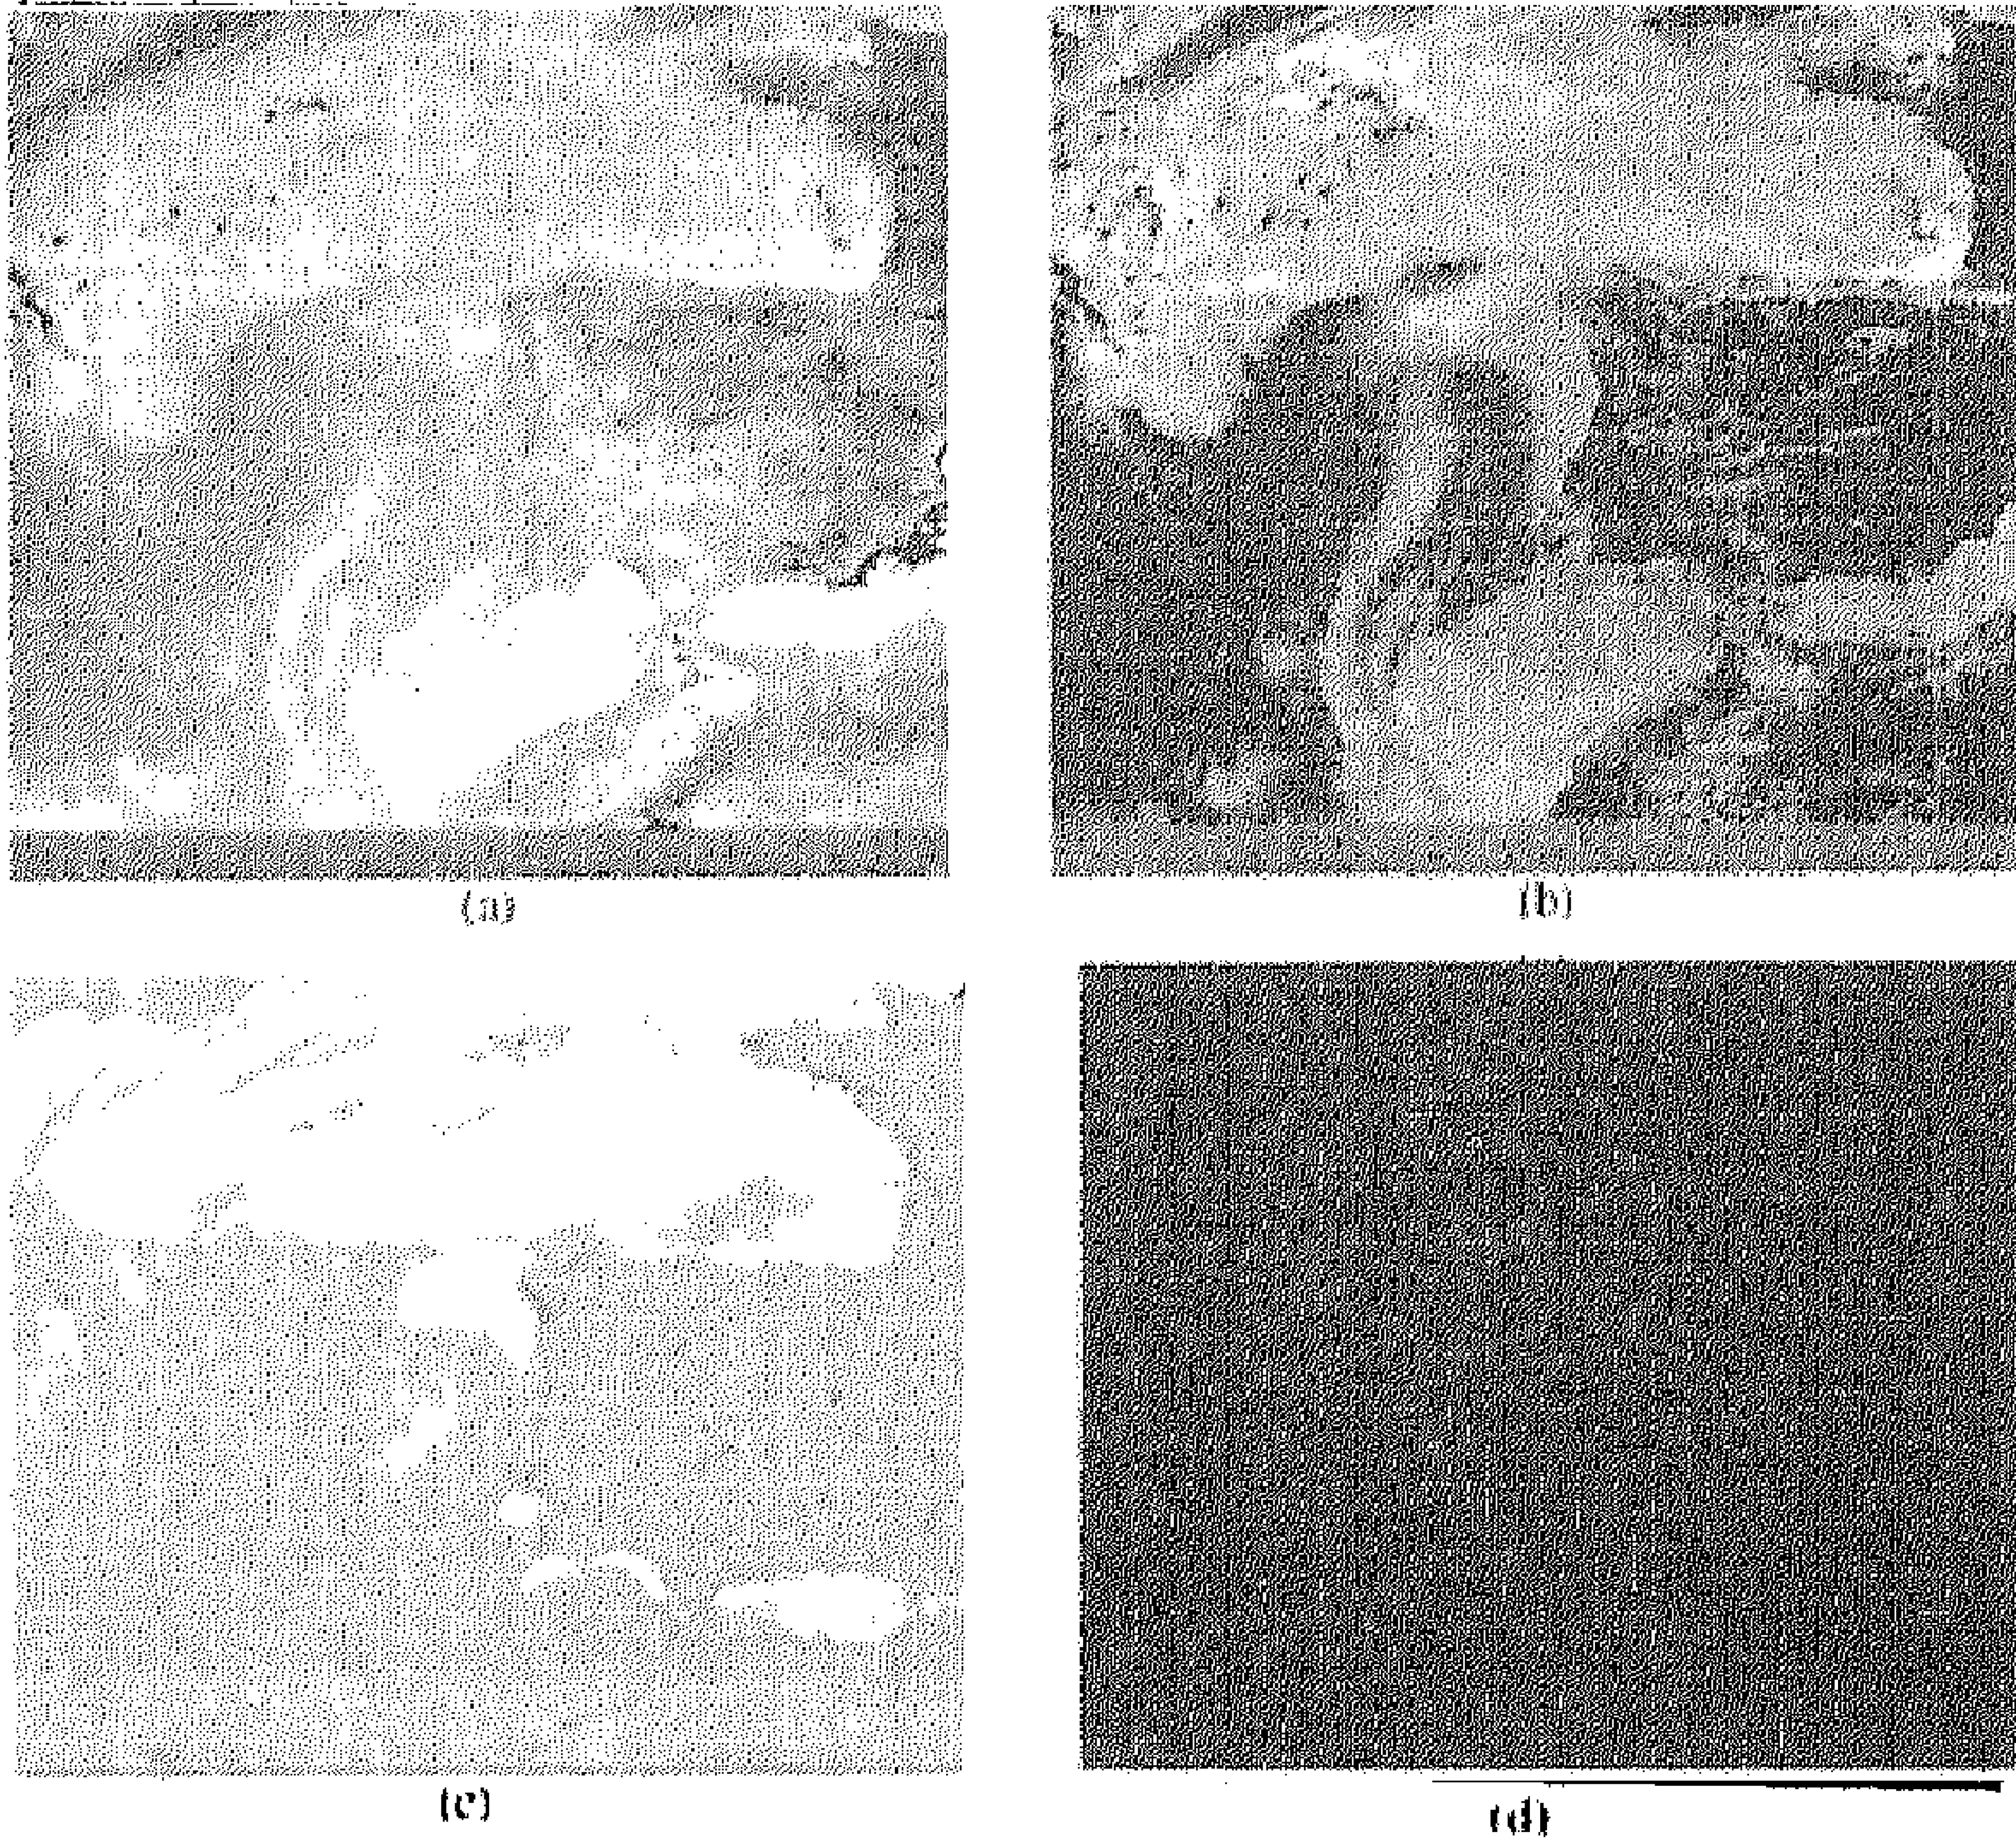
- درجة حرارة سطح البحر (SST).
- الشذوذ الحراري الأسبوعي.
- الجبهات الحرارية.

- تركيز اليخضور.
- الشذوذ الارتفاعي.

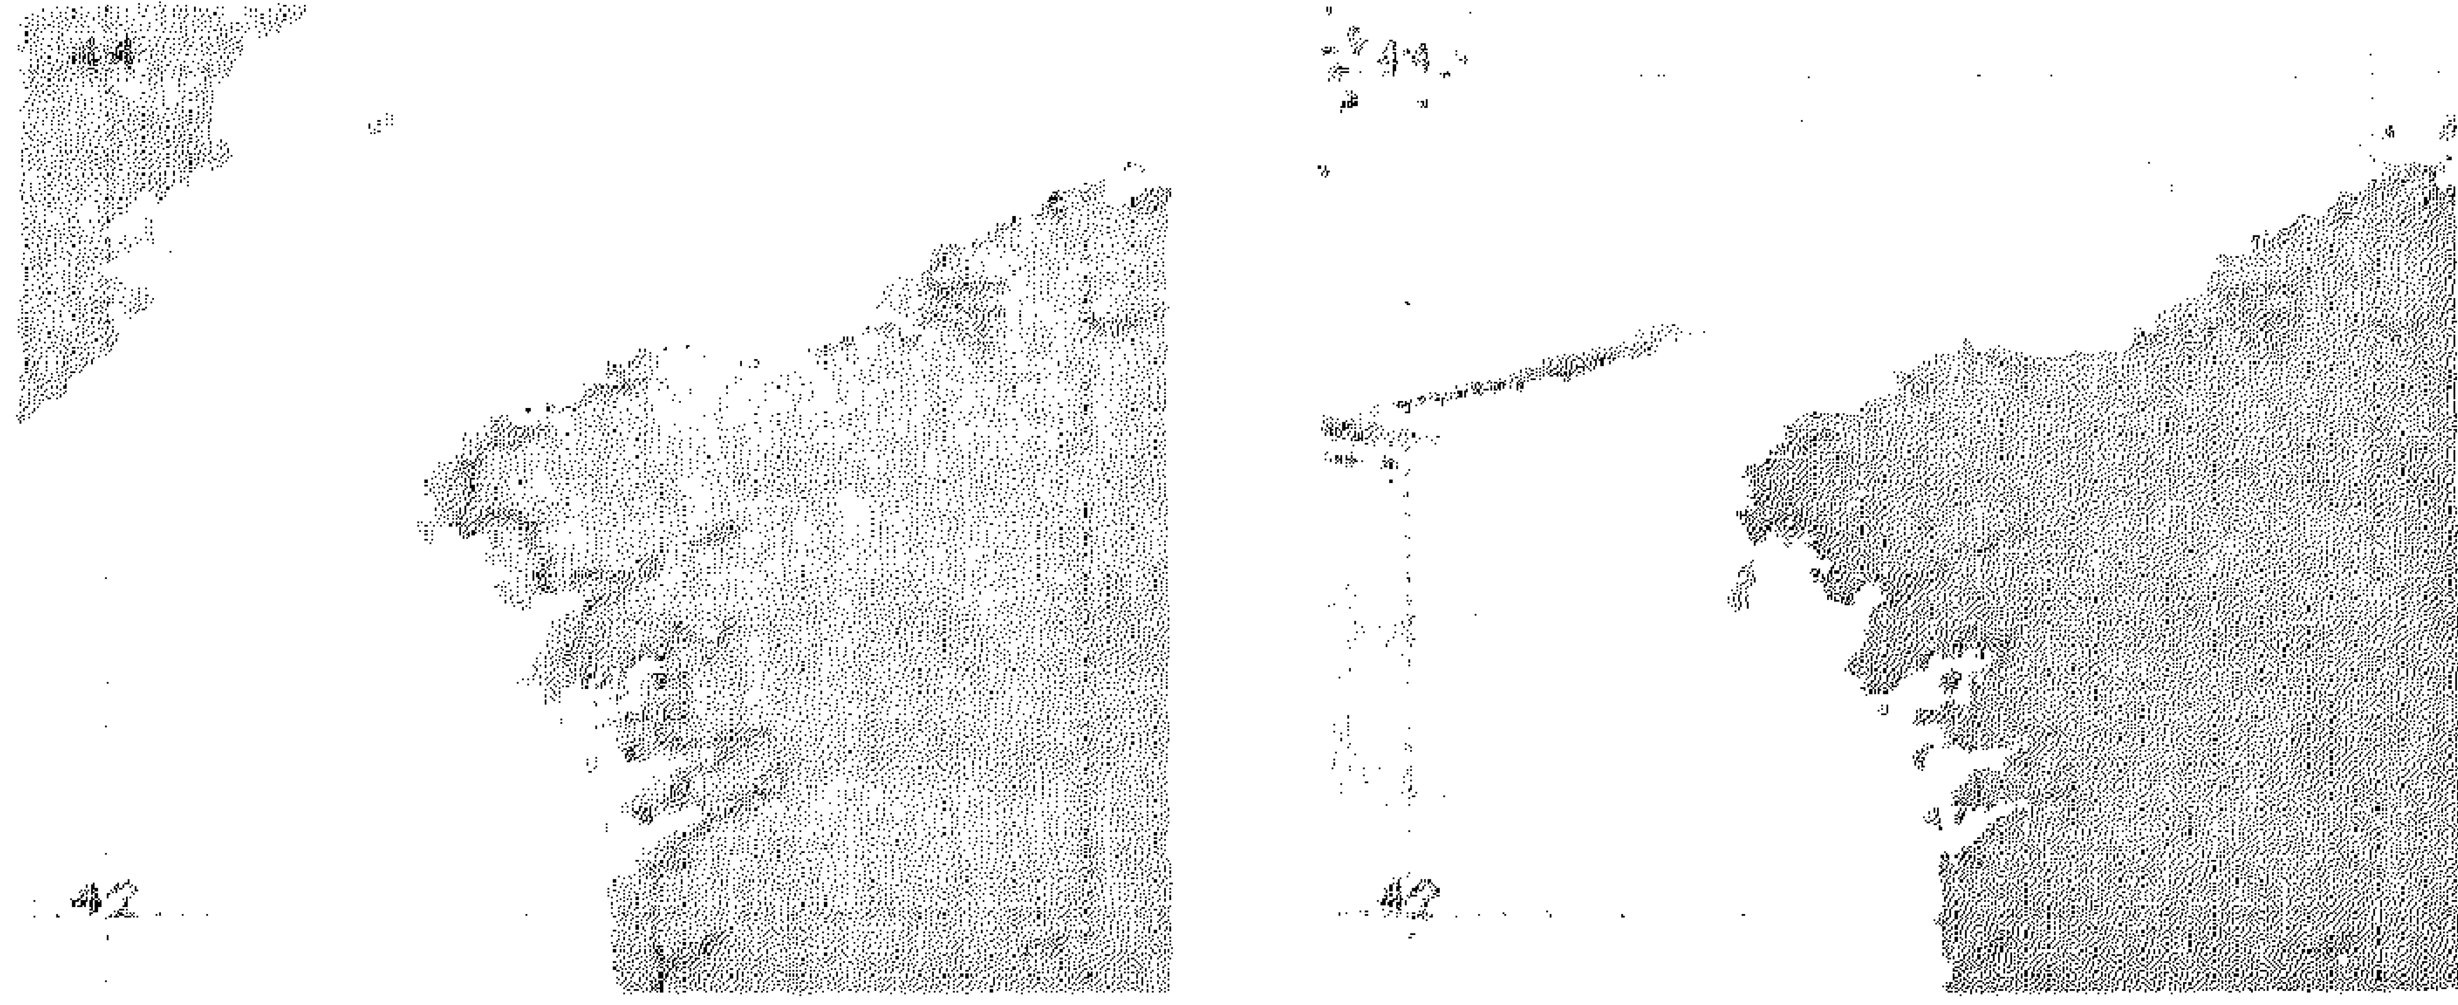
أظهرت دراسات حساسية سابقة، بأن المعلومات من الشذوذ الحراري الأسبوعي، والجبهات الحرارية، فائضة وزائدة عن الحاجة. وبالتالي، نكتم الجبهات الحرارية كدخل لنظامنا، الذي يترك المجال لعدد كبير من أنماط التدريب ذات القيم الصالحة.

يبين (الشكل 21) أربع صور مشتقة من المعالجة، التي توافق للسابع من آب عام 1998. ورد (الشكلان 21a و21b) من سلسلة القمر NOAA. كما ورد (الشكلان 21c و21d) من القمرين الصناعيين OrbView-2 وTopex-Poseidon على الترتيب. كما هو مذكور سابقاً، تستخدم سلسلة NOAA صيغة معطيات من نوع tdf، ويستخدم القمر الصناعي OrbView-2 الصيغة hdf. أما صور القمر الصناعي Topex-Poseidon فهي في الصيغة الثنائية. وكانت لغات البرمجة هي اللغة C من أجل صور القمر الصناعي NOAA واللغة IDL 5.2 من أجل صور القمر الصناعي OrbView-2. بما أنه من الأفضل أن تكون صيغة الصور مُوّحدة قبل تطبيق الشبكة العصبونية، فقد حوّلنا صورة hdf والصور الثنائية إلى صيغة tdf، بحيث يمكن لاحقاً معالجتها بشيفرات مُولدة في لغة C.

الشكل (21) *صورة مكتسبة بعد المعالجة الأولية (1998/8/7). a - درجة حرارة سطح البحر (SST، سلسلة NOAA). b - الشذوذ الحراري الأسبوعي (سلسلة NOAA). c - تركيز اليخضور (القمر الصناعي OrbView-2). d - خريطة الشذوذ الارتفاعي (القمر الصناعي Topex-Poseidon).*



***الشكل (22)** على اليسار، صورة اليخضور من القمر الصناعي OrbView-2 بأخطاء مرجعية جغرافية بسبب الإسقاط الاسطواني. على اليمين صورة من القمر الصناعي OrBiew-2 بمرجعية جغرافية صحيحة.*

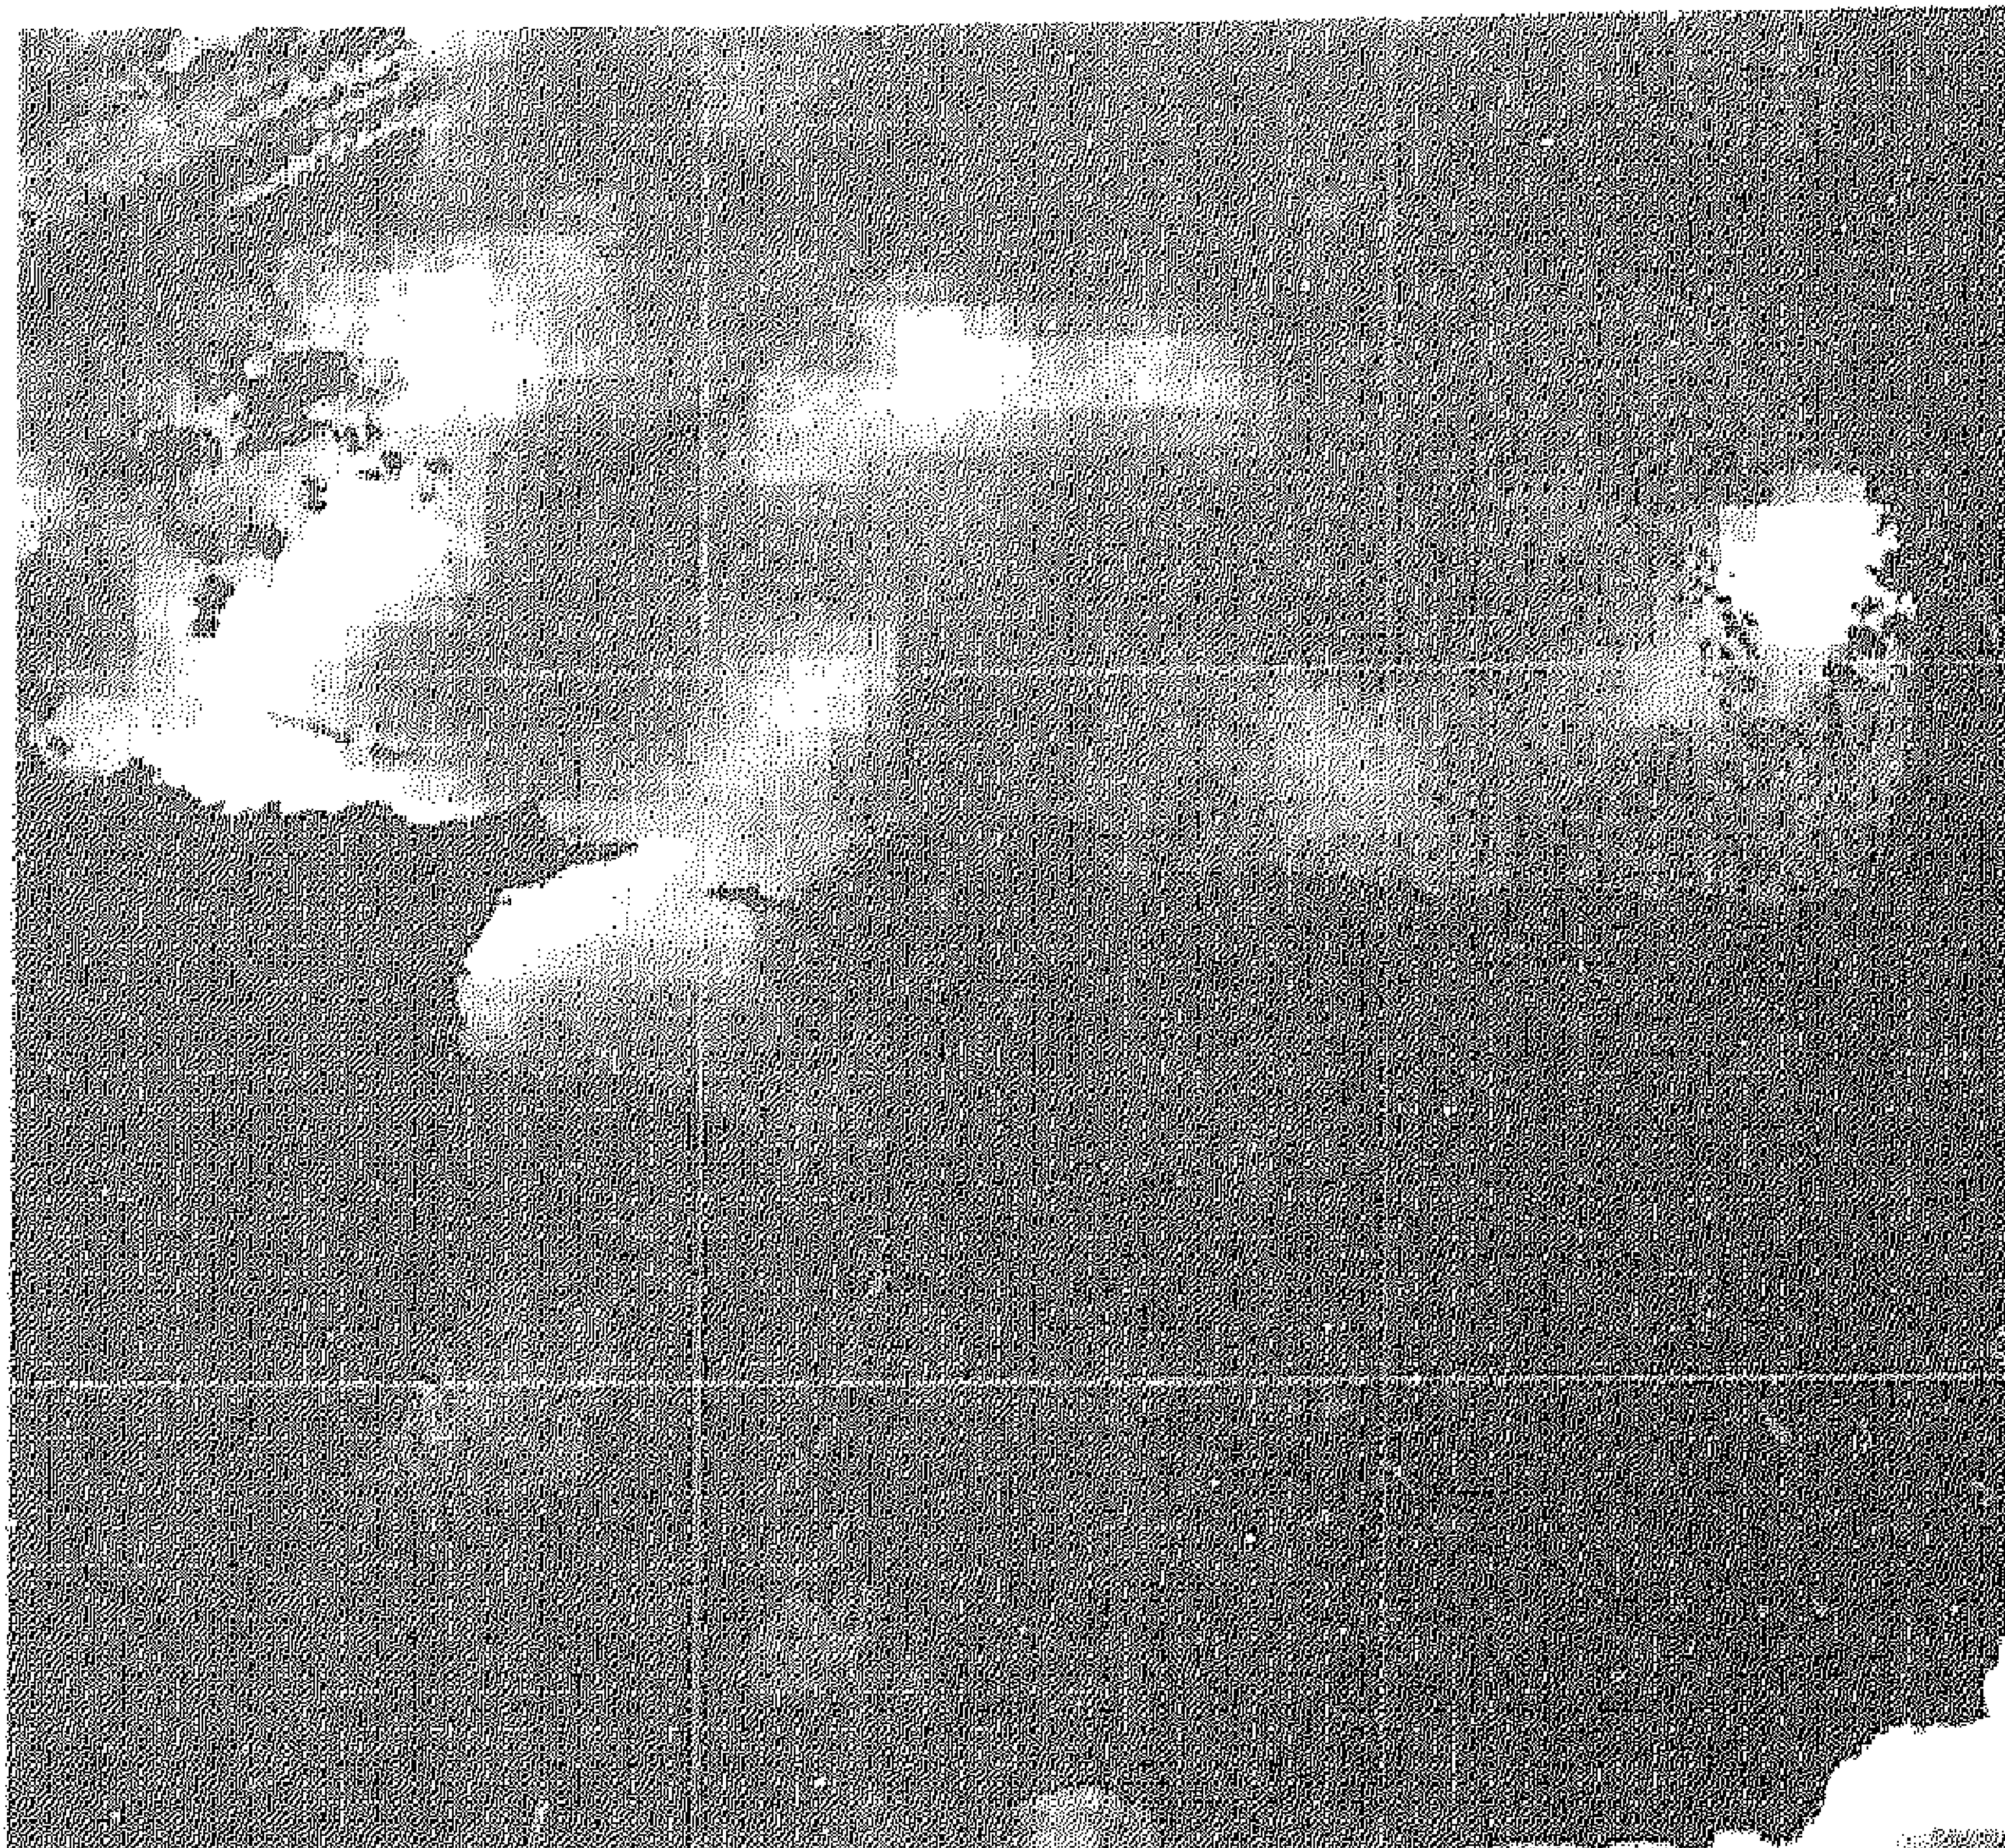


تمتلك الصيغة tdf مجالاً واسعاً من التوابع، التي تشير خصوصاً إلى معالجة الصور في الصيغة المذكورة. على الرغم من ذلك، يجب أن نتذكر تسوية التصحيح الجغرافي للصور، بحيث يتحقق تطابق بكسل – إلى – بكسل بينها لتسهيل تطبيق الخوارزمية الموافقة. يبين الشكل التالي مثالاً لصور مُصممة بشكل سيء، إذ لم يُعدّل الخط الساحلي إلى الوضع الحقيقي.

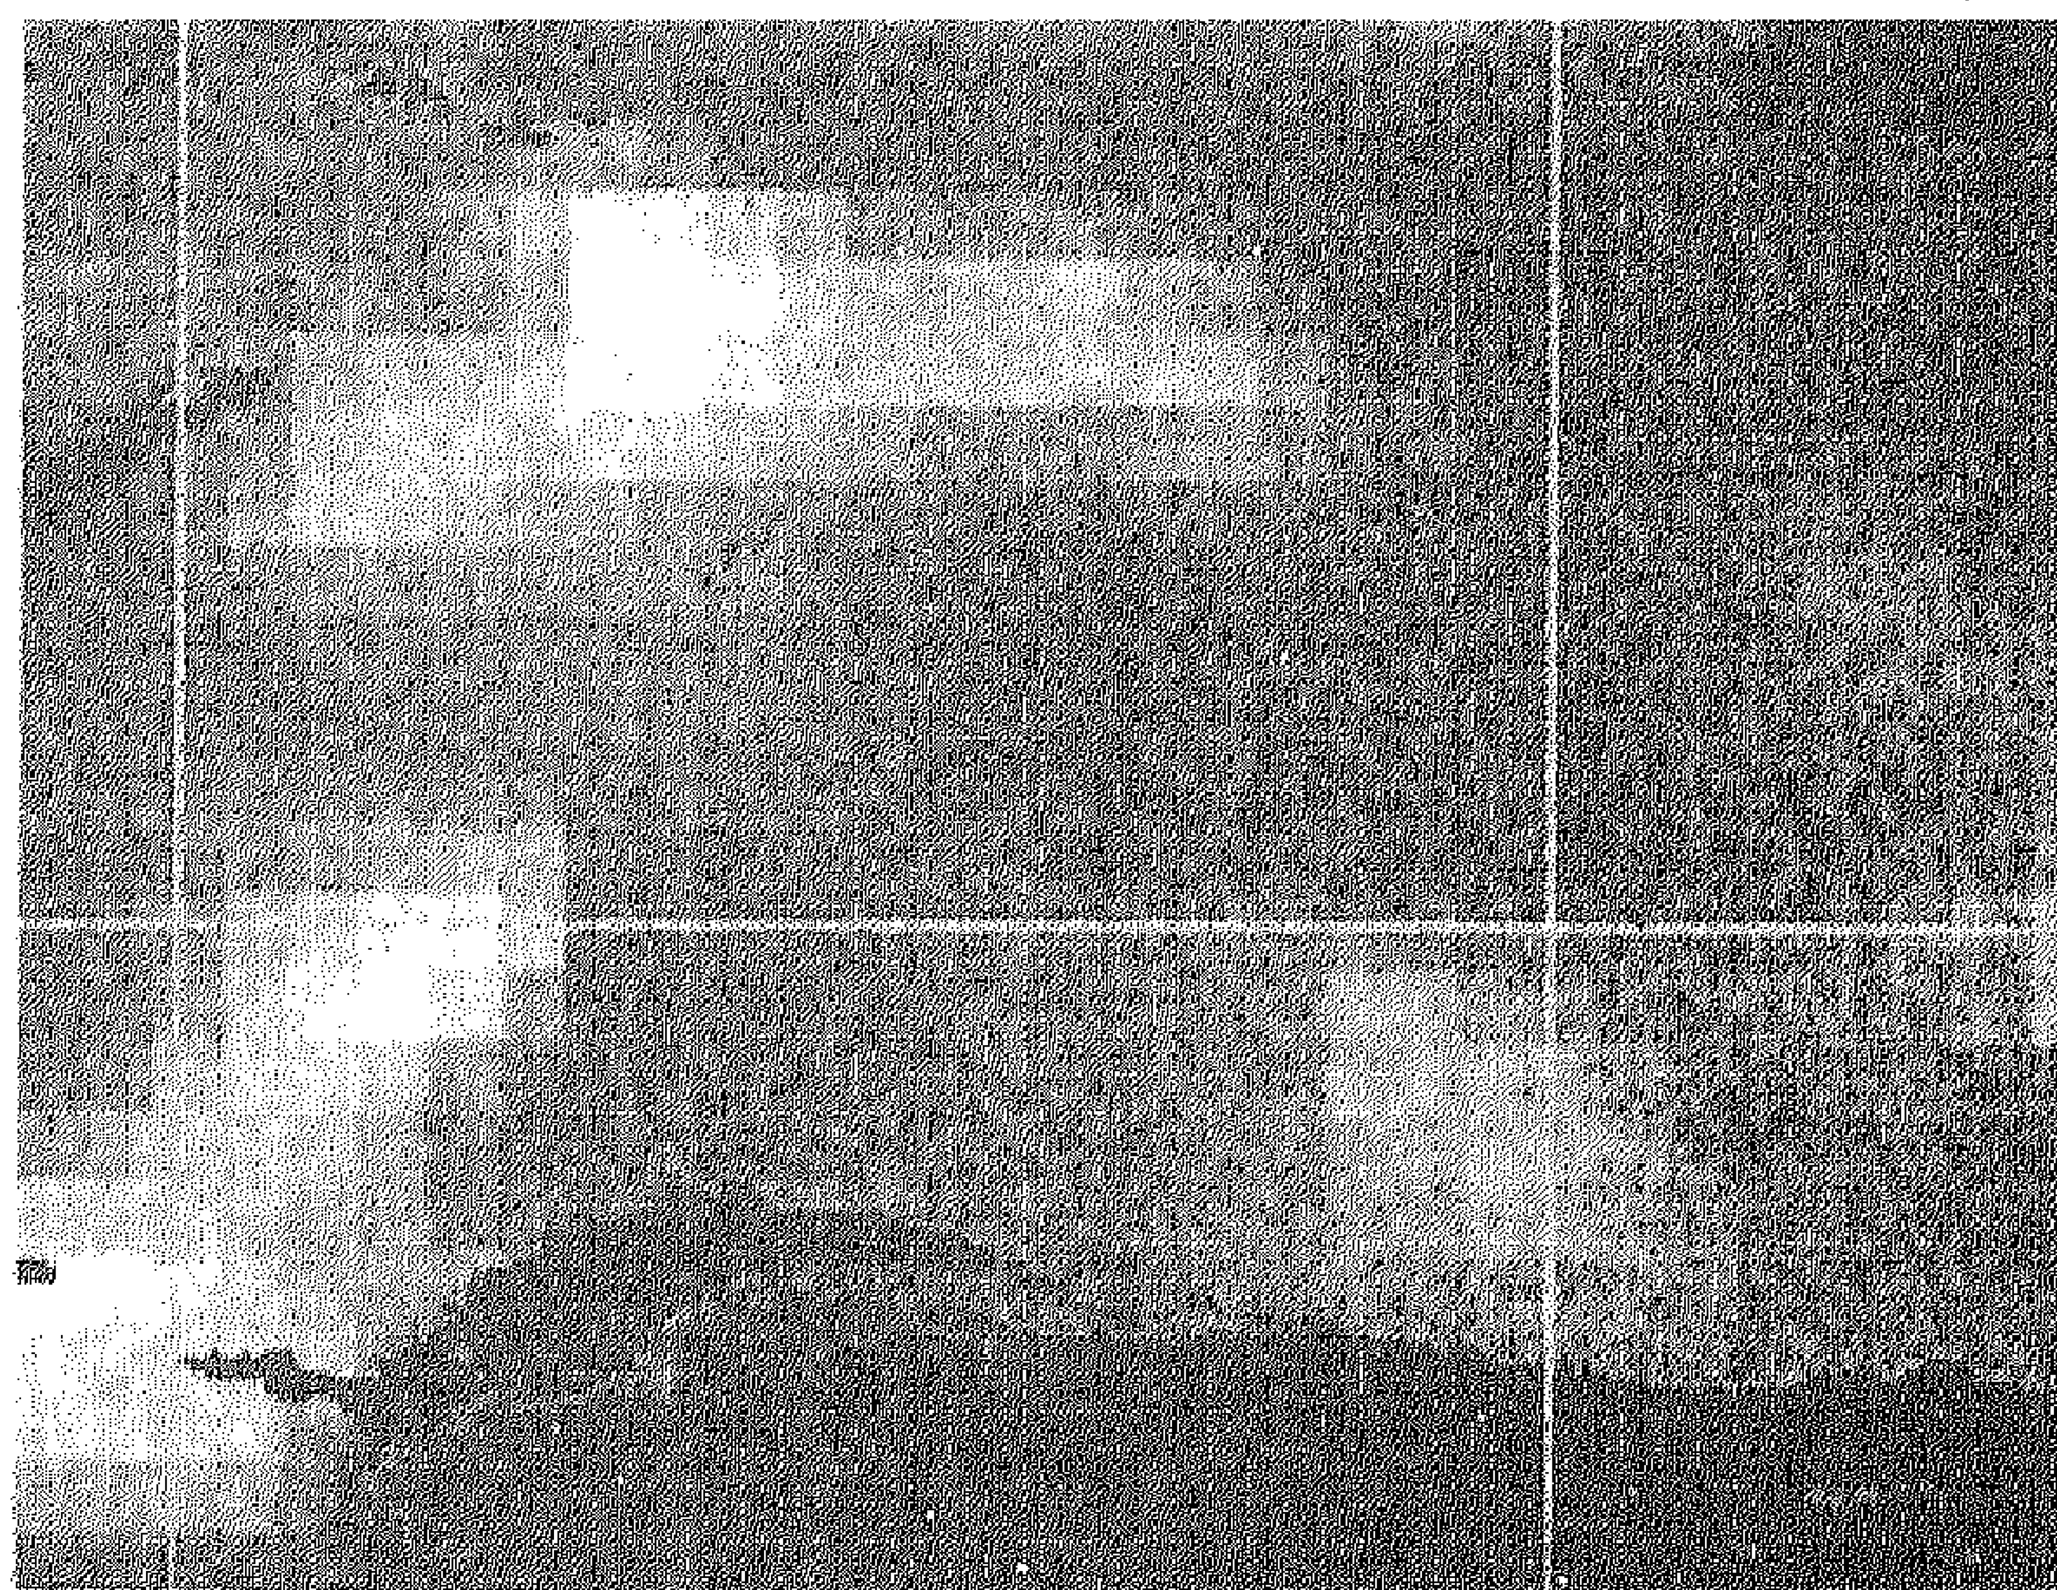
تم تفادي هذه المشكلة بتصحيح صورة الأقمار الصناعية NOAA وOrbView-2 بتصميمات متساوية البعد اسطوانية ومستطيلة على الترتيب. كلا التصميمات الجغرافية متكافئة بكسل – إلى بكسل، إذا كان لها نفس التمييز الحيزي. من أجل صورة القمر الصناعي Topex-Poseidon، حسبنا الإحداثيات الجغرافية لكل نقطة. وبعدئذ، وضعناها على صورة بدون معطيات أولية. يبين (الشكل 21) بأن التصحيح الجغرافي للصور الأربعة صحيح. يختلف التمييز الحيزي (للشكل 21d) عن مثيله للآخرين، وهو يوضح النقط المعزولة وغياب المعطيات (قيمة 0 ممثلة بالأسود): التمييز الحيزي لهذه الصورة هو 0.25° × 0.25°، وللصور الأخرى 0.025° × 0.025°.

نحن الآن مستعدين لاستخدام شبكة الانتشار الخلفي لحساب خريطة الاحتمال من أجل صيد القرش PrionaceGlauca. مدخلات الشبكة هي قيم البكسلات لكل صورة. نأخذ من الدخل، الذي يوافق الشذوذ الارتفاعي، القيمة التي لا تكون صفراً، وأقرب إلى البكسل، إذا لم يكن موجوداً. وبخرج الشبكة نولد أخيراً خريطة احتمال صيد السمك انظر (الشكل 23) التي تشير درجات اللون الرمادي الخفيف فيها إلى الاحتمالات الأعلى. نتيجة للتمييز الحيزي المنخفض للصور MSLA الواردة من القمر الصناعي – Poseidon Topex، جُمعت الاحتمالات في مربعات بقياس 0.25° × 0.25°. يظهر (الشكلان 23 و24) بصيغة tdf بنفس التصحيح الجغرافي كما للصور الأولية. ولكن إذا حوّلناهما إلى الصيغة JPEG المشهورة فيمكننا أن نستوردهما إلى GIS.

الشكل (23) *خريطة احتمال التقاطات القرش Prionace Glauca في 7-8-1998. المكتسبة بشبكة عصبونية مدربة بخوارزمية انتشار خلفي. تشير السويات الرمادية العالية (درجات اللون الخفيفة) إلى احتمالات صيد سمك عالية.*

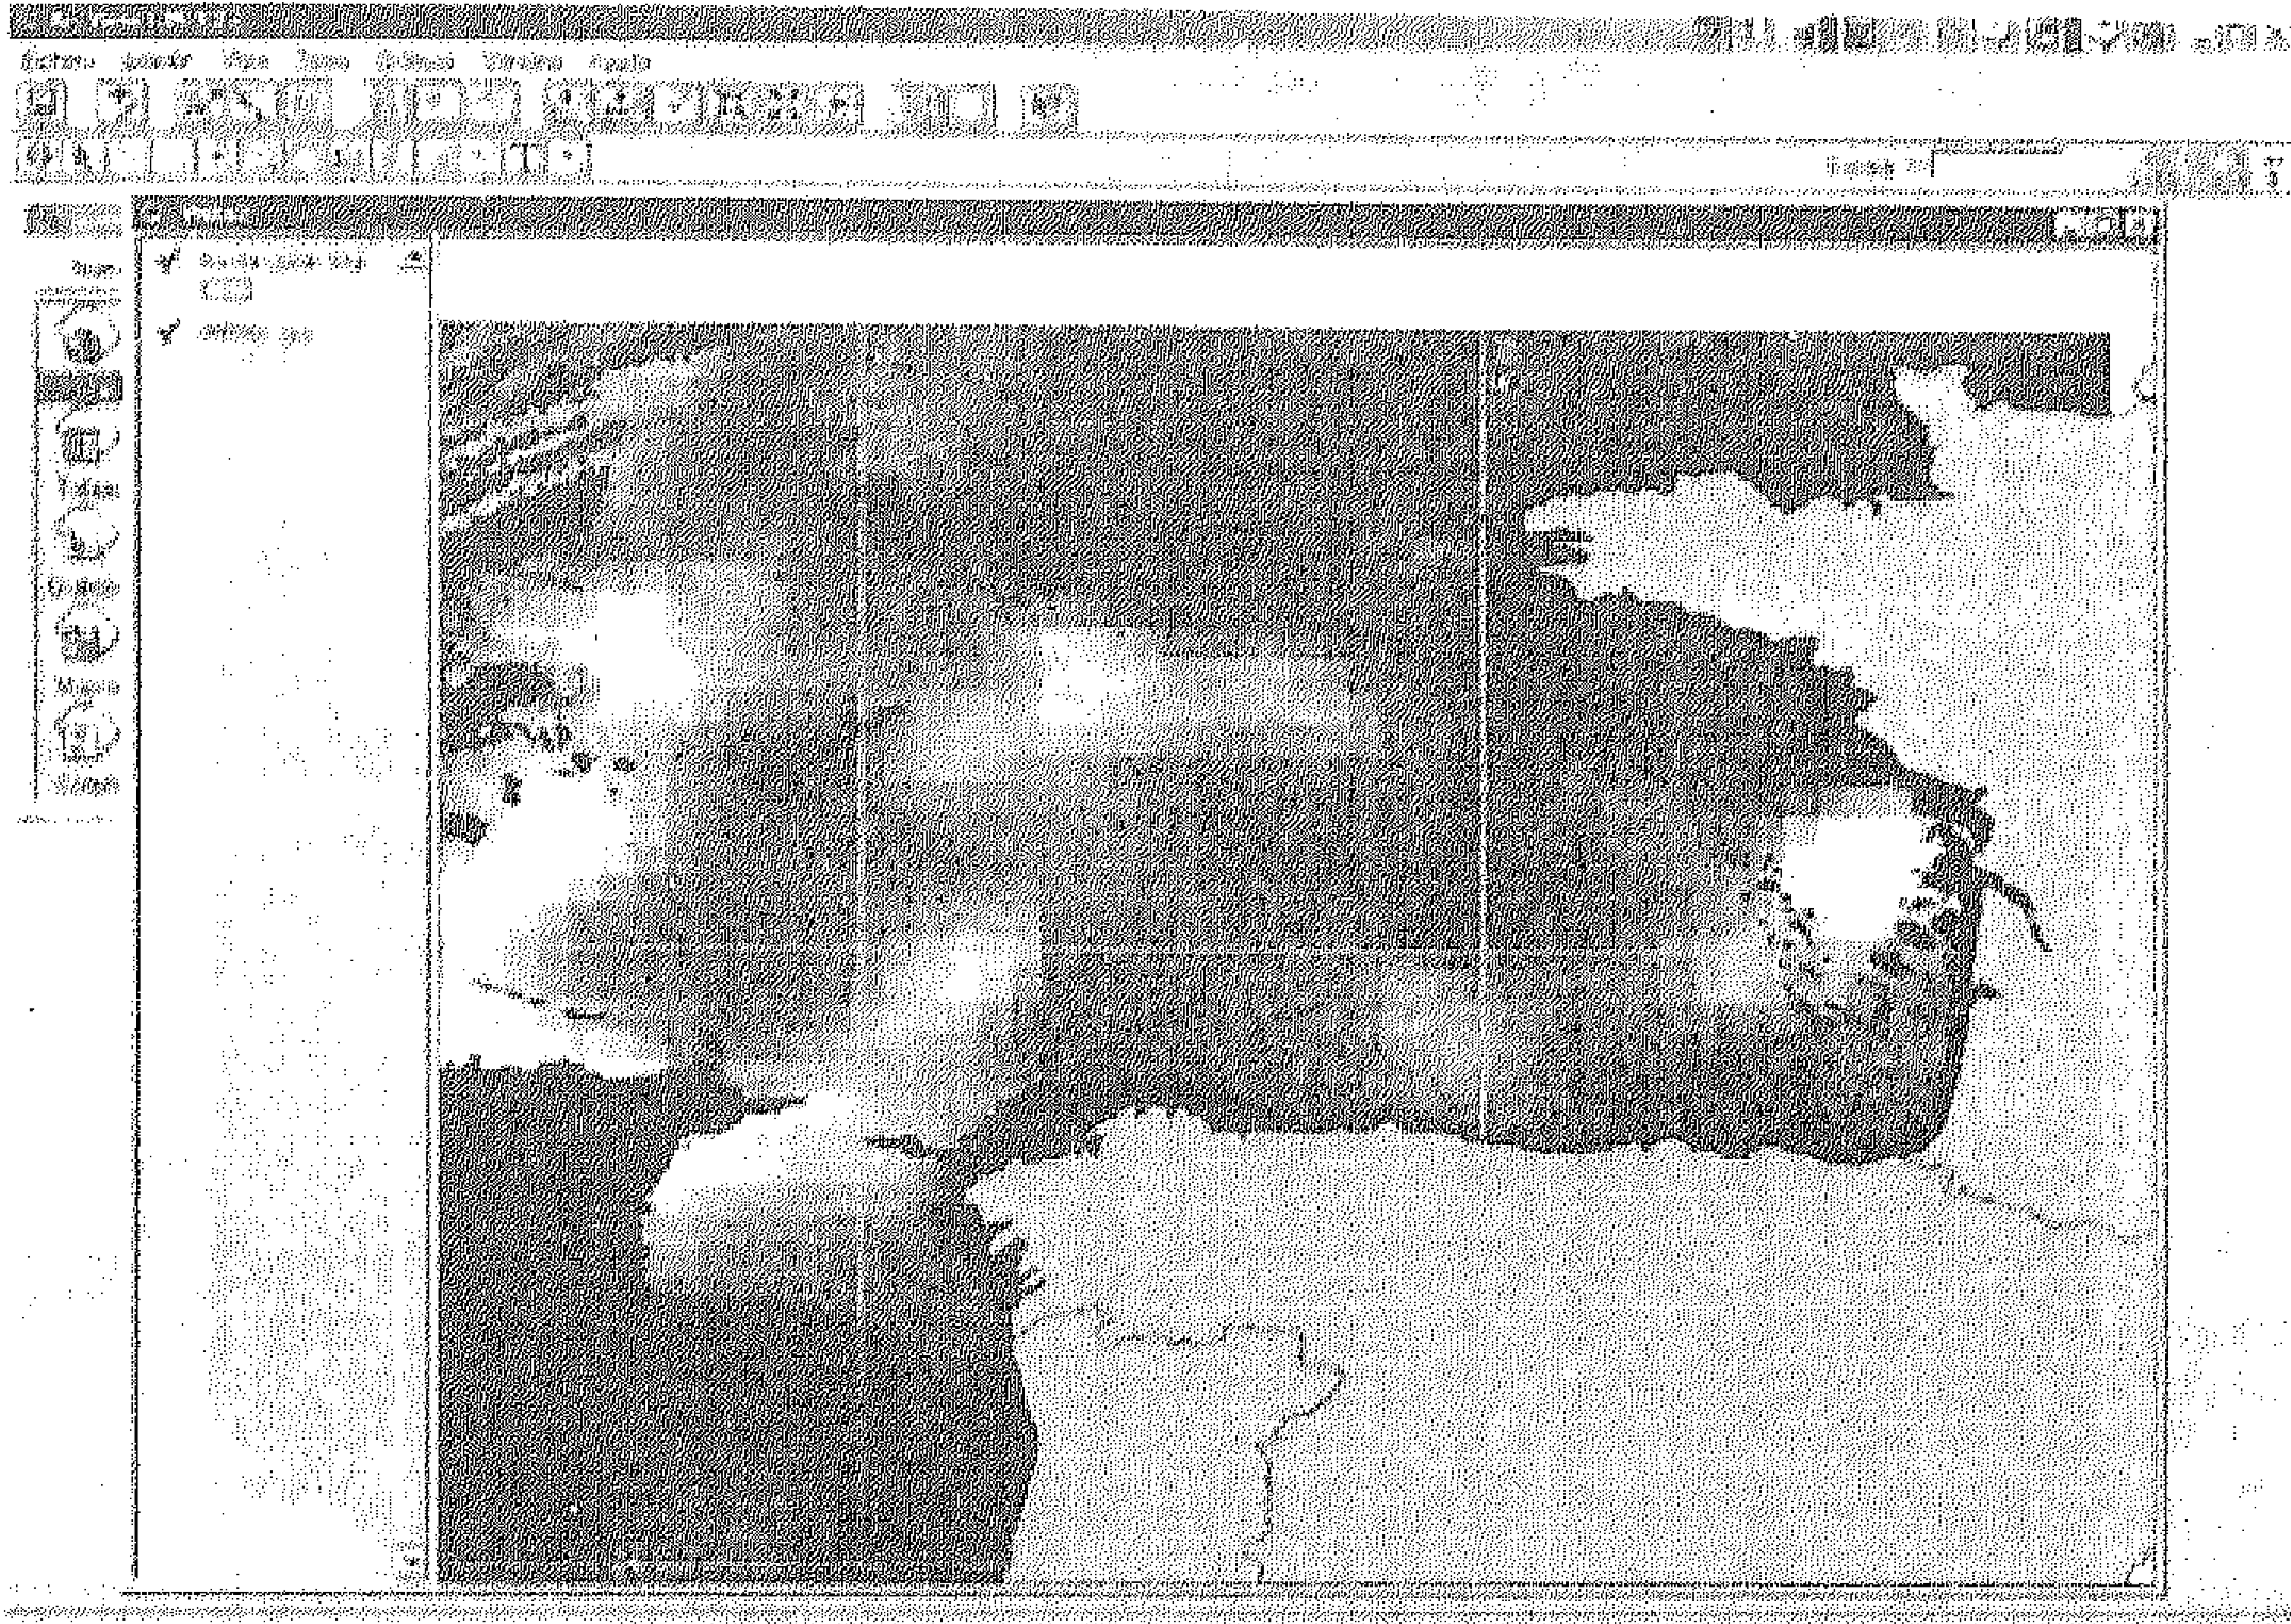


الشكل (24) *جزء من خريطة احتمال الشكل (24).*



يبين (الشكل 25) النتائج المكتسبة بـــ ArcView 3.2.

الشكل (25) *الصورة 3.19 المُصدّرة بـ ArcView 3.2.*



استنتاجات

- طوّرنا نظام دعم لاتخاذ القرار في الاستثمار العملي لمصايد السمك، بدمج تقنيات ذكاء صنعي متنوعة مع نظام اكتساب المعطيات الواردة من حساسات بعيدة.
- على أساس الصور لسنتين كاملتين (1998، 1999) والعديد من معطيات المجال، قمنا بتوليد نظام معلومات قوي، يتضمن قاعدة معطيات تابعية مُشكلّة بالبارامترات البيئية والإحداثيات الجغرافية والصيد.
- أثبت دراسة سابقة للمعطيات المتوفرة مطوّرة بشبكات Kohonen وتحليل المكونات الرئيسية، بأن متغيرات مثل الشذوذ الحراري والجبهات الحرارية، تحتوي على معلومات فائضة زائدة عن الحاجة، وبالتالي، فقد اخترنا متغير الشذوذ الحراري، لأنه يرتب أنماطاً أكثر.
- صممنا نظام دعم قرار جديد يعتمد على نظام المعلومات المذكور سابقاً. تُميّز مسألتنا بغياب الطرق العالمية والمحلية، وبعدم وجود قاعدة معرفة، والمتغيرات التي تكون بالكاد

مترابطة (إذا استثنينا الشذوذات والجبهات الحرارية). وبالتالي، فقد اخترنا خوارزميات النزعة الاتصالية في مجال الذكاء الصنعي.

- استخدمت مجموعة التدريب الناتجة في عملية التعلّم للنموذج العصبوني المُخلّق مؤخراً المسمى "بالشبكات التابعية" (نموذج ذو قابلية للفصل). وقد أسهبنا المقارنات بنظام ANFIS عصبوني عائم هجين مبتكر، بالإضافة إلى الانتشار الخلفي للشبكات العصبونية الكلاسيكية وRBF. وقد أظهرت الاختبارات بالشبكات التابعية وANFIS عدة حالات من التدريب المفرط. أما النتائج الأفضل فتم الحصول عليها بالشبكات العصبونية الكلاسيكية، وبأنظمة ANFIS هجينة بسيطة.
- نحن قادرون على تصميم عدة أدوات، تتنبأ بمناطق صيد السمك المثالية وفقاً لمعلومات من الأقمار الصناعية المتنوعة. صُدّقت النتائج المكتسبة بواسطة أنماط تختلف عن تلك، التي استخدمت خلال التدريب.
- قمنا بتطوير تطبيقات، تدمج الشبكات العصبونية والمعالجة الرقمية للصور بعد التوحيد السابق لصيغ الصور المميزة لكل قمر صناعي. يتم تضمين خرج النظام في خريطة احتمال صيد السمك المُولّدة من خرج الشبكة المستخدمة. وبنفس الوقت، قمنا بتنفيذ التطبيقات، التي تُمكننا من الوصول إلى نظام المعلومات، ولحساب التنبؤات الدقيقة. طُوّرت تلك الأدوات بأسلوب، تسمح للمستخدم بأن يستفيد من كافة الخصائص في بيئة مريحة وسهلة الوصول.

المراجع

Aronoff, S. (1991). Geographic information systems: A management perspective (2nd ed.). Ottawa, Ontario, Canada: WDL Publications.

Aurelle D., Lek, S., Giraudel, J., & Berrebi, P. (1999) Microsatellites and artificial neural networks: Tools for the discrimination between natural and hatchery brown trout (Saimo trutta, L.) in Atlantic populations. Ecological Modelling, 120, 313-324.

Aussem, A., & Hill, D. (2000). Neural-network metamodelling for the prediction of Caulerpa taxifolia development in the Mediterranean sea. Neurocomputing, 30, 71-78.

Benediktsson, H., Swain, P.H.,& Ersoy, O.K. (1990). Neural network approaches versus statistical methods in classification of multisource remote sensing data. IEEE Transactions on Geoscience and Remote Sensing, 28, 540-551.

Berenji, H.R. (1992). Fuzzy logic controllers. In R.R. Yager & L.A. Zadeh (Eds.),An introduction to fuzzy logic applications in intelligent systems (pp. 69-96). Kluwer Academic Publishers.

Brosse, S., Guegan, J., Tourenq, J., & Lek, S. (1999). The use of artificial neural network to assess fish abundance and spacial occupancy in the literal zone of a mesotropic lake. Ecological Modelling, 120. 299-311.

Castillo, E., & Gutierrez, J.M. (1998). Nonlinear time series modeling and prediction using functional networks. Extracting information masked by chaos. Physics Letters A, 244,71-84.

Castillo, E., Cobo, A., Gutiérrez, J.M., & Pruneda, E. (1999). Introduction to functional networks with applications. A neural based paradigm. Kluwer International Publishers.

Cotos, J.M. (1994, septiembre). Dinámica y clasificación de estructuras ocádnicas para aplicación operacional de pesquerías utilizando teledetección e ingenieria de conocimiento. Tesis doctoral. Departamento de Física Aplicada, Facultad de Física, Universidad de Santiago de Compostela.

Dreyfus-Leon, M.J. (1999). Individual-based modelling of fishermen search behauviour with neural networks and reinforcement learning. Ecological Modelling, 120, 287-297.

Harlow, C.A., Trivedi, M.M., & Conners, R.W. (1986). Use of texture operators in segmentation. Optical Engineering, 25(11), 1200-1206.

Haykin, S. (1999). Neural networks: A comprehensive foundation (2nd ed.). Prentice Hall.

Jang, J.-S.R. (1992, July). Neuro-fuzzy modeling: Architecture, analyses and applications. Doctoral thesis. University of California, Department of Electrical Engineering and Computer Science.

Jang, J.-S.R. (1993). ANFIS: Adaptive-network-based fuzzy inference system. IEEE Trans. Syst., Man., Cybern, 23(5), 665-685.

Komatsu, T., Aoki, I., Mitani, I., & Ishii, T. (1994). Prediction o the catch o Japanese sardine larvae in Sagami Bay using a neural network. Fisheries Science, 60(4),385-391.

Lillesand,T.M.,& Kiefer, R.N. (1987). Remote sensing and image interpretation. New York: John Wiley & Sons.

Maas, O., Boulanger, J., & Thiria,S. (2000). Use of neural networks for predictions using time series: Illustration with the El Niño Southern oscillation phenomenon. Neurocomputing, 30, 53-58.

Specht, D.F. (1990). Probabilistic neural networks. Neural Networks, 3, 109-118.

Takagi, T., & Sugeno, M. (1983, July). Derivation of fuzzy control rules from human operator's control actions. Proceedings of the IFAC Symposium on Fuay Information, Knowledge Representation and Decision Analysis (pp. 55-60).

Takagi, H., Suzuki, N., Koda, T., & Kojima Y. (1992). Neural networks desgned on approximate reasoning architecture and their applications. IEEE Trans. Neural Networks. 3(5}, 752-760.

Torres, J.A., & Cantón, M. (2000). Detección y reconocimiento de estructuras oceánicas en imágenés AVHRR en el área de las Islas Canarias y NO de África mediante técnicas de computación conexionista. Revista de la Asociacion Española de Teledetección, 13, 5-12.

Trinanes, J.A. (1998, febrero). Sistema de información basado en teledetección para ayuda a la explotación operacional de pesquerías de túnidos y otras especies pelágicas. Tesis doctoral. Departamento Electronica e Computación, Universidad de Santiago.

Trinanes, J.A., Torres, J., Tobar, A., & Hernández, C. (1994, noviembre). Clasificacionóe imágenes multiespectrales mediante redes neuronales. Revista de la Asociación Española de Teledetección, 46-54.

Wells, W.M. (March, 2,1986). Efficient synthesis of Gaussian filters by cascaded uniform filters. IEEE Trans. Pattern Analysis and Machine Intelligence, 9(2).

الفصل الرابع عشر

طريقة الشبكات العصبونية لتحقيق الحد الأدنى للكلفة في وضع جدول الإنتاج

ملخص

يعاني مدراء الكلفة العاملين في شركات التصنيع من صعوبة تحديد استراتيجية مُثلى للتحكم بالكلفة. برغم أن مفهوم ABC يمكن أن يؤمن مخططاً رائعاً من الناحية النظرية للتحكم بالكلفة، فإن المعروف على نحو واسع، بأن مدراء الكلفة لديهم مشكلة جدية في فهم المخطط ABC وتطبيقه على حالات حقيقية للتحكم بالكلفة. في هذا الاتجاه، فإن اقتراح طريقة إرشادية، يستطيع بها مدراء الكلفة الحصول على استراتيجية تحكم تقريبية بالكلفة مشابهة لتلك التي يمكن الحصول عليها بــ ABC، سيكون ذا معنىً كبيراً من وجهة نظر كلٍّ من النظرية والتطبيق. لتحقيق هذه الحاجة، نقترح استخدام نموذج الشبكة العصبونية، المسماة Pereceptron متعددة الطبقات (MLP)، بخوارزمية تعلّم ذات انتشار خلفي، ومن ثم، تقريب استراتيجية التحكم بالكلفة من ABC. إن الاهتمام الأساسي لهذه الدراسة هو استقصاء ما إذا كانت الحلول المُقرّبة بواسطة MLP صالحة من منظور إحصائي. فإن كان ذلك صحيحاً، فهذا يعني أنه يمكن أن يعتمد مدراء الكلفة على طريقة الشبكات العصبونية للمجيء باستراتيجية مثالية للتحكم بالكلفة مشابهة لتطبيق ABC. لإظهار صلاحية استراتيجية التحكم بالكلفة المقترحة باستخدام MLP، تقترح هذه الدراسة حل مسألتين ضمن السياق لوضع جدول إنتاج باستخدام ABC:

1. تقدير الكلفة الكلية المعتمد على الشبكة العصبونية (NNTCE).
2. تقدير زمن الدورة المعتمد على الشبكة العصبونية (NNCTE).

من أجل الإعداد التجريـبي، نفترض بأن منتجين مشتركين في خمسة أنواع من المتغيرات الخارجية، وثلاثة أنواع من المتغيرات الداخلية، مُصنّفان بنفس الوسيلة. تم توليد طريقة الشبكة العصبونية MLP لــ NNTCE وNNCTE بمجموعة من 180 معطيات تدريب، و125 معطيات اختبار، أُثبت جمعها لتكون متطابقة إحصائياً مع نتائج ABC.

مقدمة

في ظل المنافسة العالمية العنيفة جداً، يجب على عمليات التصنيع المعاصرة، أن تزيد الإنتاجية وتخفض الكلفة. ولهذا، فقد أصبح تقدير الكلف المختلفة للتصنيع بدقة أكثر هدفاً استراتيجياً. بينما تميل أنظمة الكلفة التقليدية إلى تحريف معلومات الكلفة باستخدام طرق التخصيص الفوقية التقليدية (تعتمد على المصادر المباشرة مثل ساعات العمل)، وكسب حساب الكلفة المعتمد على النشاط (ABC) سمعة لتقدير الكلفة ولطرق الحساب الأكثر دقةً. يتبع ABC الكلف عن طريق النشاطات المنجزة على مواضيع الكلفة (إنتاج أو نشاطات خدمية)، ويؤدي إلى معلومات كلفة دقيقة وقابلة أكثر للتقصي. يمكن أن يساعد ABC بتصنيف النشاطات مثل القيم المُضافة والقيم غير المُضافة، ويسمح بتقدير نشاطات القيم غير المُضافة (GunaseKaran & Sarhadi, 1998).

قُدّم ABC أولاً من قبل الباحثين Cooper وKaplan كبديل لتقنيات المحاسبة التقليدية (Cooper & Kaplan, 1988a, 1988b). واستُخدم منذ ذلك لحين على نحو متزايد في أنظمة تصنيع معقدة ومتعددة المستويات (Koltai, Lozano, Guerrero & Onieva, 2000) يشكل ABC علاقات بين المنتجات والموارد المستخدمة في كافة مراحل إنتاجها. ويُفضل على حسابات الكلفة الكلاسيكية، لأن ABC يعطي أسلوباً أكثر دقةً وتماسكاً لحساب كلف التصنيع (Andrea, Filho, Espozel, Maia, & Quassim, 1999)، منتجاً في حساب الكلفة العامة الدقيقة (Kee & Schmidt, 2000). طُبق ABC على صناعات متنوعة (Tsai, 1996). بما فيها الالكترونيات (Merz & Hardy, 1993)، ذاتي الحركة (خاص بالسيارات) (Miller, 1994)، الفضاء والدفاع (Soloway, 1993)، تصنيع الطائرات (Haedicke & Feil, 1991)، بناء السفن (Porter & Kehoe, 1994)، الاتصالات الهاتفية (Hodby, Thomson & Sharman, 1994)، وأنظمة التصنيع المؤتمتة المعقدة جداً ومتعددة المستويات (Spedding & Sun, 1999; Koltai et al. , 2000)، ومجالات أخرى.

مع ذلك، فإن أحدى أكثر المشاكل الحرجة المترافقة مع ABC هي الصعوبة المعروفة جيداً لتطبيقه على مسائل العالم الحقيقي بدون الحاجة إلى فهم تعقيداتها النظرية. وكما هو الحال عادةً، يتصارع مدراء الكلفة العاملين في شركات التصنيع مع مسألة إيجاد الاستراتيجية المثالية للتحكم بالكلفة. في حالة تبني المدراء مبدأ ABC، يصبح تحليل برامج التحكم بالكلفة وبناء إطار عمل مُحنّك مناسب للفلسفة الأساسية لـــ ABC أكثر صعوبة، لذا ففي أغلب الأحيان يفشل جزء منه في النهاية، مؤدياً إلى نتائج ضعيفة بعيدةً عن التوقعات. وبالتالي، فهم بحاجة إلى إيجاد طريقة بديلة – أي طريقة إرشادية – تضمن استراتيجية مثالية للتحكم بالكلفة المزيفة، والتي ستكون مشابهة لتلك المكتسبة بتطبيق ABC. في هذا الاتجاه، نقترح استخدام الشبكة العصبونية

perceptron متعددة الطبقات (MLP) (Rumelhart, Hinton, & Williams, 1986)، التي استُعملت على نطاق واسع من أجل تشكيلة من المسائل التطبيقية بغية مقاربة استراتيجية ABC المثالية للتحكم بالكلفة.

يكمن دافع البحث هنا في تزويد حل عملي لمدراء الكلفة، الذين يريدون تحقيق استراتيجية ABC للتحكم بالكلفة. وبالتالي، إذا بيّنا كيفية الحصول بنجاح على مقاربة استراتيجيية ABC للتحكم بالكلفة بتطبيق MLP تقليدية، فيمكن عندها الادعاء بشكل مؤكد، بأن نموذج الشبكة العصبونية التقليدية مثل MLP المُدرب بخوارزمية تعلّم ذات انتشار خلفي، يمتلك الإمكانية المطلوبة لكي يُستخدم بسهولة من قبل مدراء الكلفة في البيئة الحقيقية، الرامي لتحقيق استراتيجية تحكم بالكلفة تمتلك نفس الجودة لحل ABC المُدار.

لنفترض بأن هدف منظومة تصنيع هو خلق منتجين باستخدام سبعة متغيرات خارجية، وأربعة متغيرات داخلية، ويهدف مدير الكلفة لإيجاد استراتيجية ABC المثالية للتحكم بالكلفة بتطبيق الشبكة العصبونية MLP المُدربة بخوارزمية تعلّم ذات انتشار خلفي. اعتماداً على هذا الافتراض، فإن الأهداف الرئيسية لهذا الفصل تكون مضاعفة.

يكمن الهدف الأول في وصف نشاطات التصنيع النموذج الرياضي، يحسب كلف حمل الجرد لكل منتج، وكلف الإعداد الكلي، والكلفة الكلية بالساعة للمنتجين باستخدام تحليل ABC وفق سيناريوهات مختلفة، تدمج سبعة متغيرات خارجية، وأربعة متغيرات داخلية. أما الهدف الثاني، فهو تنفيذ تجارب الشبكة العصبونية لمقارنة استراتيجية ABC المثالية للتحكم بالكلفة، التي تُحلّل إلى جزأين فرعيين:

1. تقدير الكلفة المعتمد على الشبكة العصبونية (NNTCE) باستخدام مجموعة من 180 من معطيات التدريب، و125 من معطيات الاختبار المُولّدة بدمج المتغيرات الخارجية والداخلية.
2. تقدير زمن الدورة المعتمد على الشبكة العصبونية (NNCTE) باستخدام 60 حالة مختلفة، ثم تُنفذ اختبارات إحصائية صارمة بغية مقارنة خرج NNTCE وNNCTE مع نظيره للكلفة الكلية النظرية، وزمن الدورة، مبرزاً أفضليات طريقة الشبكة العصبونية MLP المّدربة بخوارزمية تعلّم ذات انتشار خلفي لمقاربة استراتيجية ABC المثالية للتحكم بالكلفة. يؤمن القسم الثاني من هذا الفصل مراجعةً للخلفية وللمادة المنشورة وثيقة الصلة بالموضوع. يصف القسم الثالث المنهجية التي نستخدمها لإنتاج مخرجات NNTCE وNNCTE ملاءمة. أما التجارب والاختبارات الإحصائية الموافقة فقد عُنْونت في القسم 4. يلخص القسم 5 نتائجنا ويقدم اقتراحات للبحث المستقبلي.

مراجعة المادة المنشورة والخلفية

طرق تقدير الكلفة

يمكن أن تُصنّف طرق تقدير الكلفة كحدسية، أو قياسية (تناظرية)، أو بارامترية، أو تحليلية.

تعتمد الطرق الحدسية على الخبرة السابقة للمقدّر (الشخص القائم بالتقدير). وبالتالي، فهي تخضع بشكل حاسم للانحياز المُقدِّر في الحكم والحساب. بما أنه من الصعب جداً أيضاً إيجاد مُقدّرين ماهرين بشكل محترف، فهناك عدة عوائق لتبني الطرق الحدسية كأسلوب نظامي لتقدير الكلفة.

تقدر الطرق القياسية كلفة المنتجات بمقارنتها مع منتجات أخرى مماثلة، تكون كلفها معلومة. تؤمن هذه الطريقة أسلوباً قوياً مريحاً لتقدير الكلفة في المراحل المبكرة لحساب كلفة عقد التأمين.

تقدر الطرق البارامترية كلف منتج ما من البارامترات المستخدمة من قبل مصممه، والتي تؤثر على الكلفة على نحو متوقع، بحيث تُمثل باستخدام معادلة بسيطة. تميل بارامترات تقدير الكلفة البارامترية لتمييز منتج بدون وصفه بالكامل (Duverlie & Castelain, 1999). على سبيل المثال، وضح الباحثان Boothroyd & Reynelds (1989) استخدام الحجم والوزن للأجزاء المُحوّلة النموذجية كبارامترات من أجل مقاربة تقديرات الكلف.

يوجد عدد كبير من الدراسات التي تركز على طرق تقدير الكلفة التحليلية. فقد طُوِّر الباحثان Luong & Spedding (1995) نظاماً عاماً معتمداً على المعرفة لمعالجة التخطيط وتقدير الكلفة لصنع فجوة الكترونية. في حين استخدم الباحث Takakuwa (1997) المحاكاة لتقدير الكلفة من أجل نظام تصنيع مرن يعتمد على تحليل ABC. وجمع الباحثون Yong, Parsaei, Leep. and Wong (1998) معلومات من عملية التخطيط والجدولة وحساب الكلفة في تفصيل أكثر. وبغية تحديد الكلفة الإجمالية لخطط العملية البديلة، كما استخدم الباحثون Kiritsis, Neuendorf, & Xiruchakis (1999) نماذج شبكية لحساب كلفة تخطيط العملية المُثلى. ABC هي أيضاً طريقة تحليلية، التي تفكّك العمل المطلوب إلى مهمات أولية أو عمليات أو نشاطات بكلف معلومة – أو محسوبة بسهولة – (Copper & Kaplan, 1988a, 1988b). يمكن إيجاد مراجعة ومقارنة حساب الكلفة التقليدية وتحليل ABC في (Park and Kim 1995). سنشرح تفاصيل أكثر عن ABC فيما يلي.

ABC

نظرة عامة

تساعد أنظمة ABC لحساب الكلفة المعتمدة على النشاط المصممين في فهم البارامترات التي تؤثر بشكل غير مباشر وتدعم المصادر. تختلف أنظمة ABC عن الأنظمة التقليدية في أن أحواض كلفتها تُعّرف كنشاطات بدلاً من مراكز كلفة الإنتاج، وتختلف سواقات الكلفة المستخدمة لتعيين كلف نشاطها بنيوياً عن تلك المستخدمة في أنظمة الكلف التقليدية (Lewis, 1995). تحدد طريقة ABC المواد والنشاطات، التي تستهلك المصادر وتدير الكلف كعدد الوحدات المُنتجة، وساعات العمل، وساعات زمن التجهيز، وعدد الطلبات المستلمة. يعين ABC كلف النشاطات لوحدات الإنتاج أو المواضيع كلف أخرى مثل الزبائن، الخدمات ... وهلم جراً. تم تركيز البحث حول أنظمة ABC – وفقاً لذلك – على تيارين رئيسين: اختبار سواقات (محركات) الكلفة المثلى (Levitan & Gupta, 1996; Schniederjans & Gravin, 1997)، وتقدير الكلفة (Bode, 1998a, 1998b).

اختيار سواقات الكلفة المثلى

بما أن الهدف الرئيس لهذا الفصل هو استخدام الشبكة العصبونية كطريقة بحث تجريـبي، فسنلخص أولاً المادة المنشورة التي تثبت فعالية تقنيات البحث التجريبية لاختيار سواقات الكلفة المثلى (Babad & Balachandran, 1993; Levitan & Gupter, 1996). حاول الباحثان Babad & Balachandran (1993) أَمْثَلة هذه السواقات في ABC باستخدام خوارزميات طمّاعة، بينما جرب الباحثان Levitan & Gupta (1996) أَمْثَلة اختيار سواقات الكلفة ذات الصلة باستخدام الخوارزمية الوراثية في أنظمة ABC.

وقد وجدا بأن الخوارزمية الوراثية لا تخفض فقط كلف جمع المعلومات عبر سواقات أقل، وإنما تُنتج أيضاً كلفاً أكثر دقةً. اقترح الباحثان Schniederjans & Garvin (1997) عملية تدرج تحليلية مريحة (AHP)، وبرمجة هدف صفر – واحد لاختيار سواقات الكلفة ذات الصلة في ABC، وبيّنا كيف يمكن دمج تشغيل AHP في نموذج برمجة الهدف صفر – واحد، لتضمين تقنيات المصادر في عملة اختيار سواقة الكلفة.

تقدير الكلفة

تفترض ABC بشكل عام تابع كلفة خطي. أشار الباحثون Horngren, Foster, and Datar (1997) توابع الكلفة لاتكون دائماً خطية من الناحية العملية، وإنما تبدي في الحقيقة سلوكاً لا خطياً في

بعض الأحيان. وقد وضعوا كتابع كلفة توابع لا خطية التي لا يشكل فيها الرسم البياني للكلف الكلية مقابل سواقة الكلفة وحيدة خطأ مستقيماً ضمن المجال ذي الصلة. وبهذا الأسلوب، قد يُحرّف ABC التقليدي كلف الإنتاج، عندما يُظهر نشاط كلفة وسلوكاً لا خطياً.

أُستخدمت الشبكة العصبونية على نطاق واسع في المجالات المشكلة، التي تظهر مستوى لا خطية عالٍ كتوقع إفلاس البنوك (Tam & Kiang, 1992; Sexton, Sriram, & Etheridge, 2003)، والتعرف على المتوالية الزمنية (Lee & oh, 1996). اعتماداً على النجاح التجريبي الذي حققوه في دراسة اللاخطية، حاول الباحثون التغلب على خطية توزيع الكلفة باستخدام ABC تقليدية والشبكة العصبونية (Bode, 1998a, 1998b، Garza & Rouhana, 1995; Creese & Li, 1995، Smith & Mason, 1997).

أهمية الدراسة

كما ذكر سابقاً، كانت الشبكة العصبونية مفيدة في التعامل مع اللاخطية المُضمنة في مسائل الهدف. إن أنظمة ABC، التي افترضت أصلاً الخطية في سلوك الكلفة فيما يتعلق بالسواقات، قد دُعمت بنجاح بالشبكات العصبونية، التي دمجت اللاخطية في تقديرات الكلف (Bode, 1998a, 1998b). كانت مسائل الهدف لهذا الفصل – NNTCE وNNCTE – مقصودة للمساهمة في فرضية أن الشبكات العصبونية يمكن أيضاً أن تُستخدم لتأمين دعم لصانعي القرار، الذين يريدون توقع الكلفة الكلية وزمن الدورة في وضع جدولة الإنتاج.

تمت دراسة تقدير الكلفة المعتمد على الشبكات العصبونية في ABC – مثل NNTCE – على نحو واسع (Garza & Rouhana, 1995; Creese & Li 1995; Bode, 1998a, 1998b، Simth and Mason, 1997). ولكن لم تبين أي دراسة، بأنه يمكن أن تُستخدم الشبكات العصبونية بشكل آني من أجل تقدير الكلفة (NNTCE)، وتوقع زمن الدورة (NNCTE).

المنهجية

الشبكة العصبونية MLP

إن نموذج الشبكة العصبونية المُتبنّى في هذه الدراسة هو MLP، وخوارزمية تعلّمه هي الانتشار الخلفي (Rumelhart et al., 1986) MLP بخوارزمية تعلم ذات انتشار خلفي على نطاق واسع لبحث التصنيف في الأعمال. تتضمن الأمثلة طريقة اختيار جرد محاسبة (Liang, Chandler, Han, & Roan, 1992)، وتنبؤاً بالإفلاس (Tam & Kiang, 1992)، وتخمين الصكوك (Surkan & Singleton, 1990).

يمكن أن يعالج نموذج الشبكة العصبونية المعطيات المشوشة، وتضبط بارامترات النموذج بشكل متكيف عند مصادفة بيئات جديدة. وهو أداة دعم قرار بمساعدة الحاسب، التي كسبت أهمية في اتخاذ قرارات العمل (Bell, Ribar, & Verchio, 1990، Etheridge, Sriram & Hsu, 2000، Montagno, Sexton, & Simth, 2002)، بتمييز الأنماط الخطية واللاخطية المتضمنة في مجموعات المعطيات. اعتماداً على هذه الأنماط، تصنّف الشبكة العصبونية MLP المعطيات إلى فئات منفصلة، تساعد الجداء في عملية اتخاذ القرار (Liang et. al., 1992). هناك عدة خصائص لنموذج الشبكة العضوية MLP تجعلها أداة دعم قرار جذابة. إن نماذج MLP هي تقنيات تصنيفية وتنبؤية، ولكن بسبب استخدامها لخوارزمية تعلّم ذات انتشار خلفي، التي تقارب التجربة العملية، يمكن أن يُستخدم خرجها لدعم اتخاذ القرار، وعندما تُختار بعناية وتُستخدم مع تدريب كاف، تكون قادرة على مساعدة المدراء بتمييز الاتجاهات بالتعلم من المعطيات ووضع التنبؤات. تزيد مثل هذه النوعيات وثوقية الشبكة العصبونية MLP أثناء التصنيف والتنبؤ (Etheridge & Sriram, 1997; Fanning & Cogger, 1994).

وضع جدول الإنتاج

يُصمم وضع جدول إنتاج هذا الفصل لتضمين منتجين والمتغيرات الخارجية المبينة في (الجدول 1). بفرض أن:

1. المنتجات مُصنفة بمساهمة وسيلة مشتركة.
2. مطلوب إنتاج قدرة كاملة: $d_1 + d_2 = p$
3. لا يمكن أن يتم إنتاج المنتجات في نفس الوقت، بل يجب أن تتناوب في الإنتاج، ومتغير القرار هو زمن الدورة T ساعة.

الجدول (1) المتغيرات الخارجية.

	المنتج 1	المنتج
المطلوب بالساعة	d1	d2
الإنتاج بالساعة	p	p
كلفة حمل الجرد بالساعة	m1	m2
كلفة الأعداد لكل إعداد	S	S

اعتماداً على هذه الفرضيات، نحسب تابع الكلفة الكلية. الكلفة الكلية بالساعة (TC) هي مجموعات كلف حمل الجرد للمنتج 1 (IC_1)، وكلف حمل الجرد للمنتج 2(IC_2)، وكلف الإعداد (SC).

يحسب IC_i أو IC بالساعة للمنتج i $(i = 1, 2)$ كالتالي: $IC_i = m_i \times AI$، حيث أن m_i - ترمز إلى IC_i بالساعة، وAI_i هو الجرد المتوسط. و(1/2) × جرد أعظمي. والجرد الأعظمي هو: $(p-d_i)$ × زمن تشغيل الإنتاج t_i (= d_iT/P)، وبالتالي IC_i هو: $m_i \times 1/2\ (p-d_i)\ d_i\ T/P$. SC الكلي بالساعة من أجل المنتجين هو S/T، الذي يكون متناقصاً في T. من أجل دور مُعطى L (سنة على سبيل المثال) يُحسب SC الكلي كالآتي:

$$2S/T \times L = 2S \times (L/T) = 2S \times N$$

حيث أن $N = (L/T)$ ـــ هو عدد الإعدادات في الدور L.

تُحسب الكلفة الكلية بالساعة من أجل المنتجين (TC) كالآتي:

$$TC = IC_1 + IC_2 + SC$$

يجب ذكر أنه يوجد مبادلة بين IC وSC. يُرسم على (الشكل 1) شكل بياني باستخدام محورين للجرد والزمن. يكمن هدف وضع جدولة الإنتاج في تخفيض TC إلى الحد الأدنى، لتقييم المحاكاة المعتمدة على الشبكة العصبونية، نقوم بحساب القيمة المُثلى لزمن الدورة T كعلاقة منسوب.

تحسب T المثلى كالآتي:

$$T = 2\sqrt{\frac{S}{m_1(1-d_1/P)d_1 + m_2(1-d_2/P)d_2}}$$

$$T = 2\sqrt{\frac{S_P}{m_1(P-d_1)d_1 + m_2(P-d_2)d_2}}$$

ويكون AI_i المثالي هو كالتالي:

$$AI_i = 1/2(P-d_i)d_i/P \times 2\sqrt{\frac{S}{m_1(1-d_1/P)d_1 + m_2(1-d_2/P)d_2}}$$

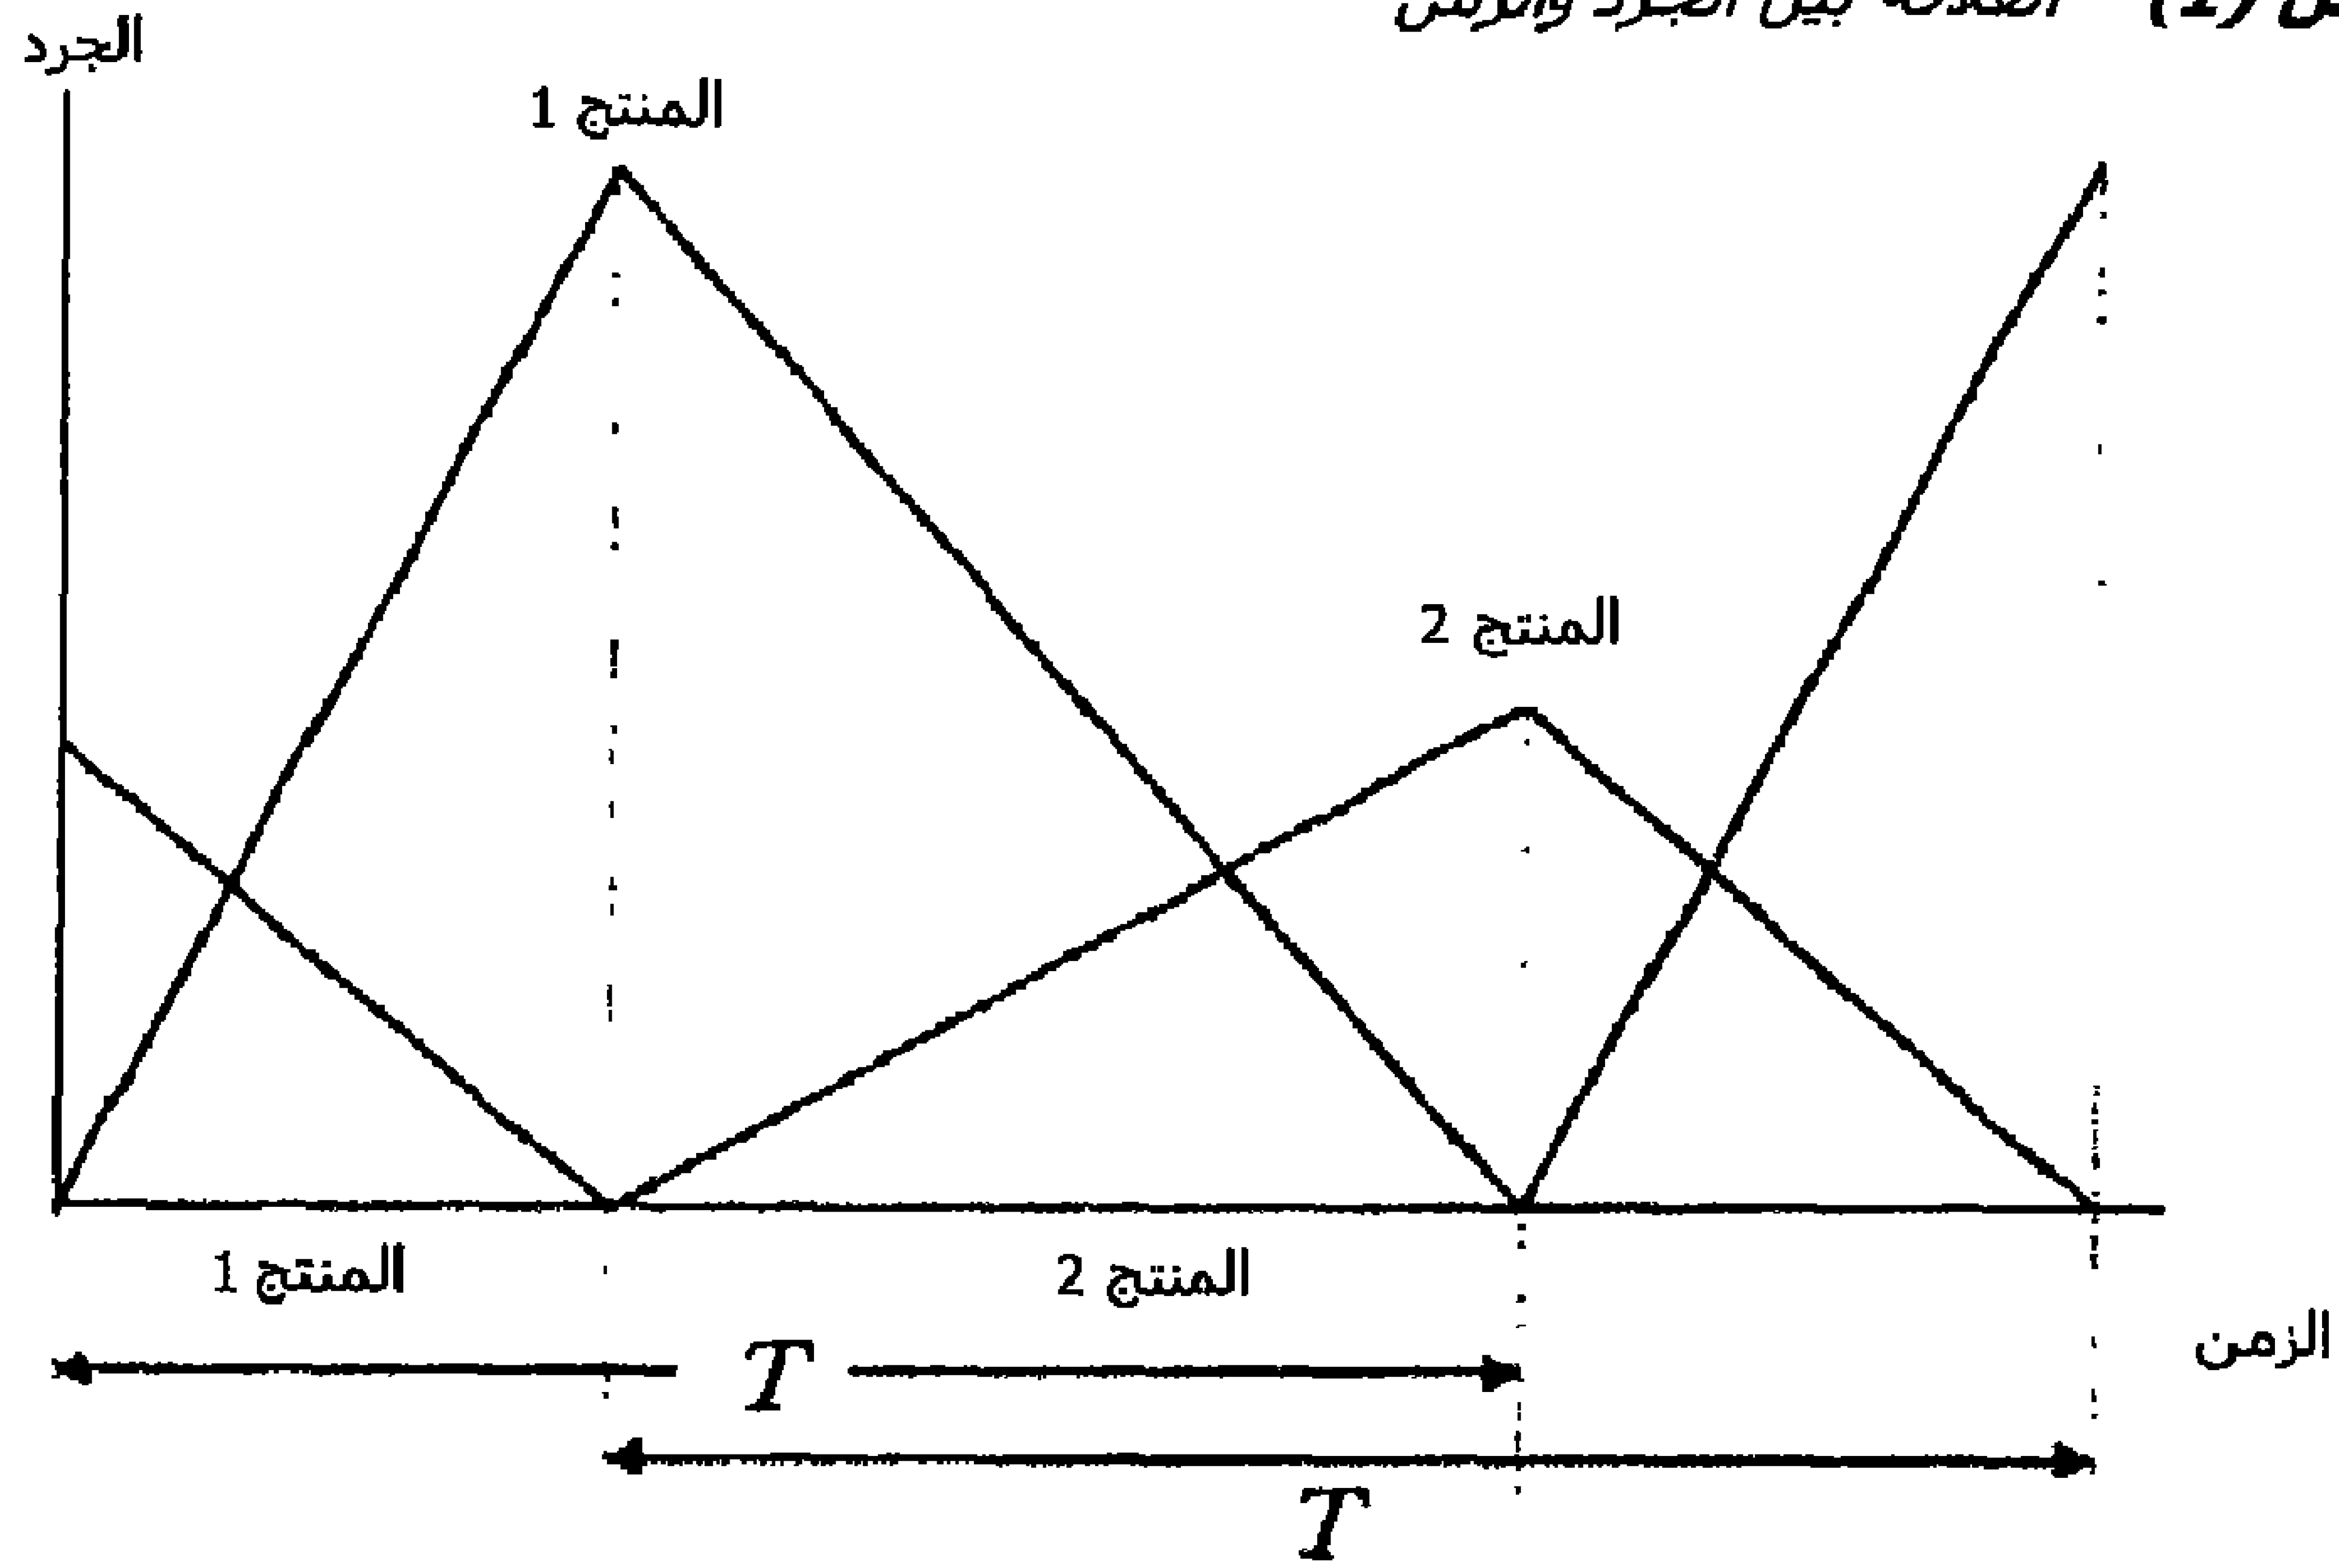
$$= (P-d_i)d_i\sqrt{\frac{S}{m_1(1-d_1)Pd_1 + m_2(P-d_2)Pd_2}}$$

ويُحسب N المثالي كالآتي:.

$$N = L/T = L/\left[2\sqrt{\frac{S}{m_1(1-d_1/P)d_1 + m_2(1-d_2/P)d_2}}\right]$$

$$= (1/2) \times L\sqrt{\frac{m_1(1-d_1/P)d_1 + m_2(1-d_2/P)d_2}{S}}$$

الشكل (1) العلاقة بين الجرد والزمن



الآلية المقترحة

اعتماداً على الميزات المذكورة للشبكات العصبونية، نقترح استخدام الخطوات التالية لحل مسائل NNTCE وNNCTE:

الخطوة 1: تابع الكلفة الحقيقي

يرمز لتابع الكلفة الحقيقي بـــ $C = f^T(E, D)$ حيث أن:

E – تمثل شعاع المتغيرات الخارجية (الإنتاج والبارامترات المتعلقة بالكلفة).

D – شعاع متغيرات القرار.

يُعرّف القرار الأفضل $D^T(E)$ بأنه الشعاع D الذي يخفض التابع $f^T(E, D)$ إلى الحد الأدنى من أجل E معطى. تكمن المشكلة هنا في تقريب شعاع القرار الأفضل $D^T(E)$ باستخدام الشبكة العصبونية.

الخطوة 2: تقريب الشبكة العصبونية

تُطبق الشبكة العصبونية على تابع الكلفة الحقيقي مؤديةً لتقريب التابع $C = f^T(E, D)$. يُرمز إلى القرار الأفضل المعتمد على الشبكة العصبونية بـــ $D^N(E)$، الذي يُعّرف كشعاع D يخفض التابع $f^N(E, D)$ إلى الحد الأدنى من أجل E معطى.

الخطوة 3: المقارنة

أولاً، نقارن $D^T(E)$ و$D^N(E)$، ثم تقارن الكلفة الصغرى الحقيقية $C = f^T(E, D^T(E))$ والكلفة الصغرى المعتمدة على الشبكة العصبونية $C = f^T(E, D^N(E))$.

التجارب

تُنفذ تجارب الشبكة العصبونية باستخدام قيم افتراضية لسبعة متغيرات خارجية، وأربعة متغيرات داخلية مذكورة في (الجدول 2). تتألف الشبكة العصبونية MLP المستخدمة من أجل التجارب من 7 × 13 × 5 × 4، حيث تعني 7 سبع عصبونات في طبقة الدخل، وتعني 13 ثلاثة عشر عصبوناً في الطبقة الخفية الأولى، وتعني 5 خمس عصبونات في الطبقة الخفية الثانية، وتعني 4 أربعة عصبونات في طبقة الخرج، على الترتيب. تمثل عصبونات الدخل سبعة متغيرات خارجية، بينما تمثل عصبونات الخرج أربعة متغيرات داخلية كما هو مبين في (الجدول 2).

الجدول (2) قائمة المتغيرات

نوع المتغير	الاسم (البارامتر)	القيمة
متغيرات خارجية	الإنتاج بالساعة (p)	20
	المطلوب بالساعة لكل منتج 1 (d1)	10
	المطلوب بالساعة لكل منتج 2(d2 = p-d1)	10
	كلفة الجرد بالساعة لكل منتج 1 (m1)	1
	كلفة حمل الجرد بالساعة لكل منتج 1(m2)	6
	كلفة الأعداد لكل إعداد (S)	80
	زمن الدورة (T)	2* SQRT(S/((m1 * (1 - d1/P) * d1) + m2 * (1 - d2/P) * d2))
متغيرات داخلية	كلفة حمل الجرد بالساعة للمنتج 1(IC1)	m1 * (1 - d1/P) * d1/2* T
	كلفة حمل الجرد بالساعة للمنتج 2 (IC2)	m2 * (1 - d2/P) * d2/2* T
	كلفة الأعداد الكلية (SC)	2* S/T
	الكلفة الكلية (TC)	IC1 + IC2 + SC

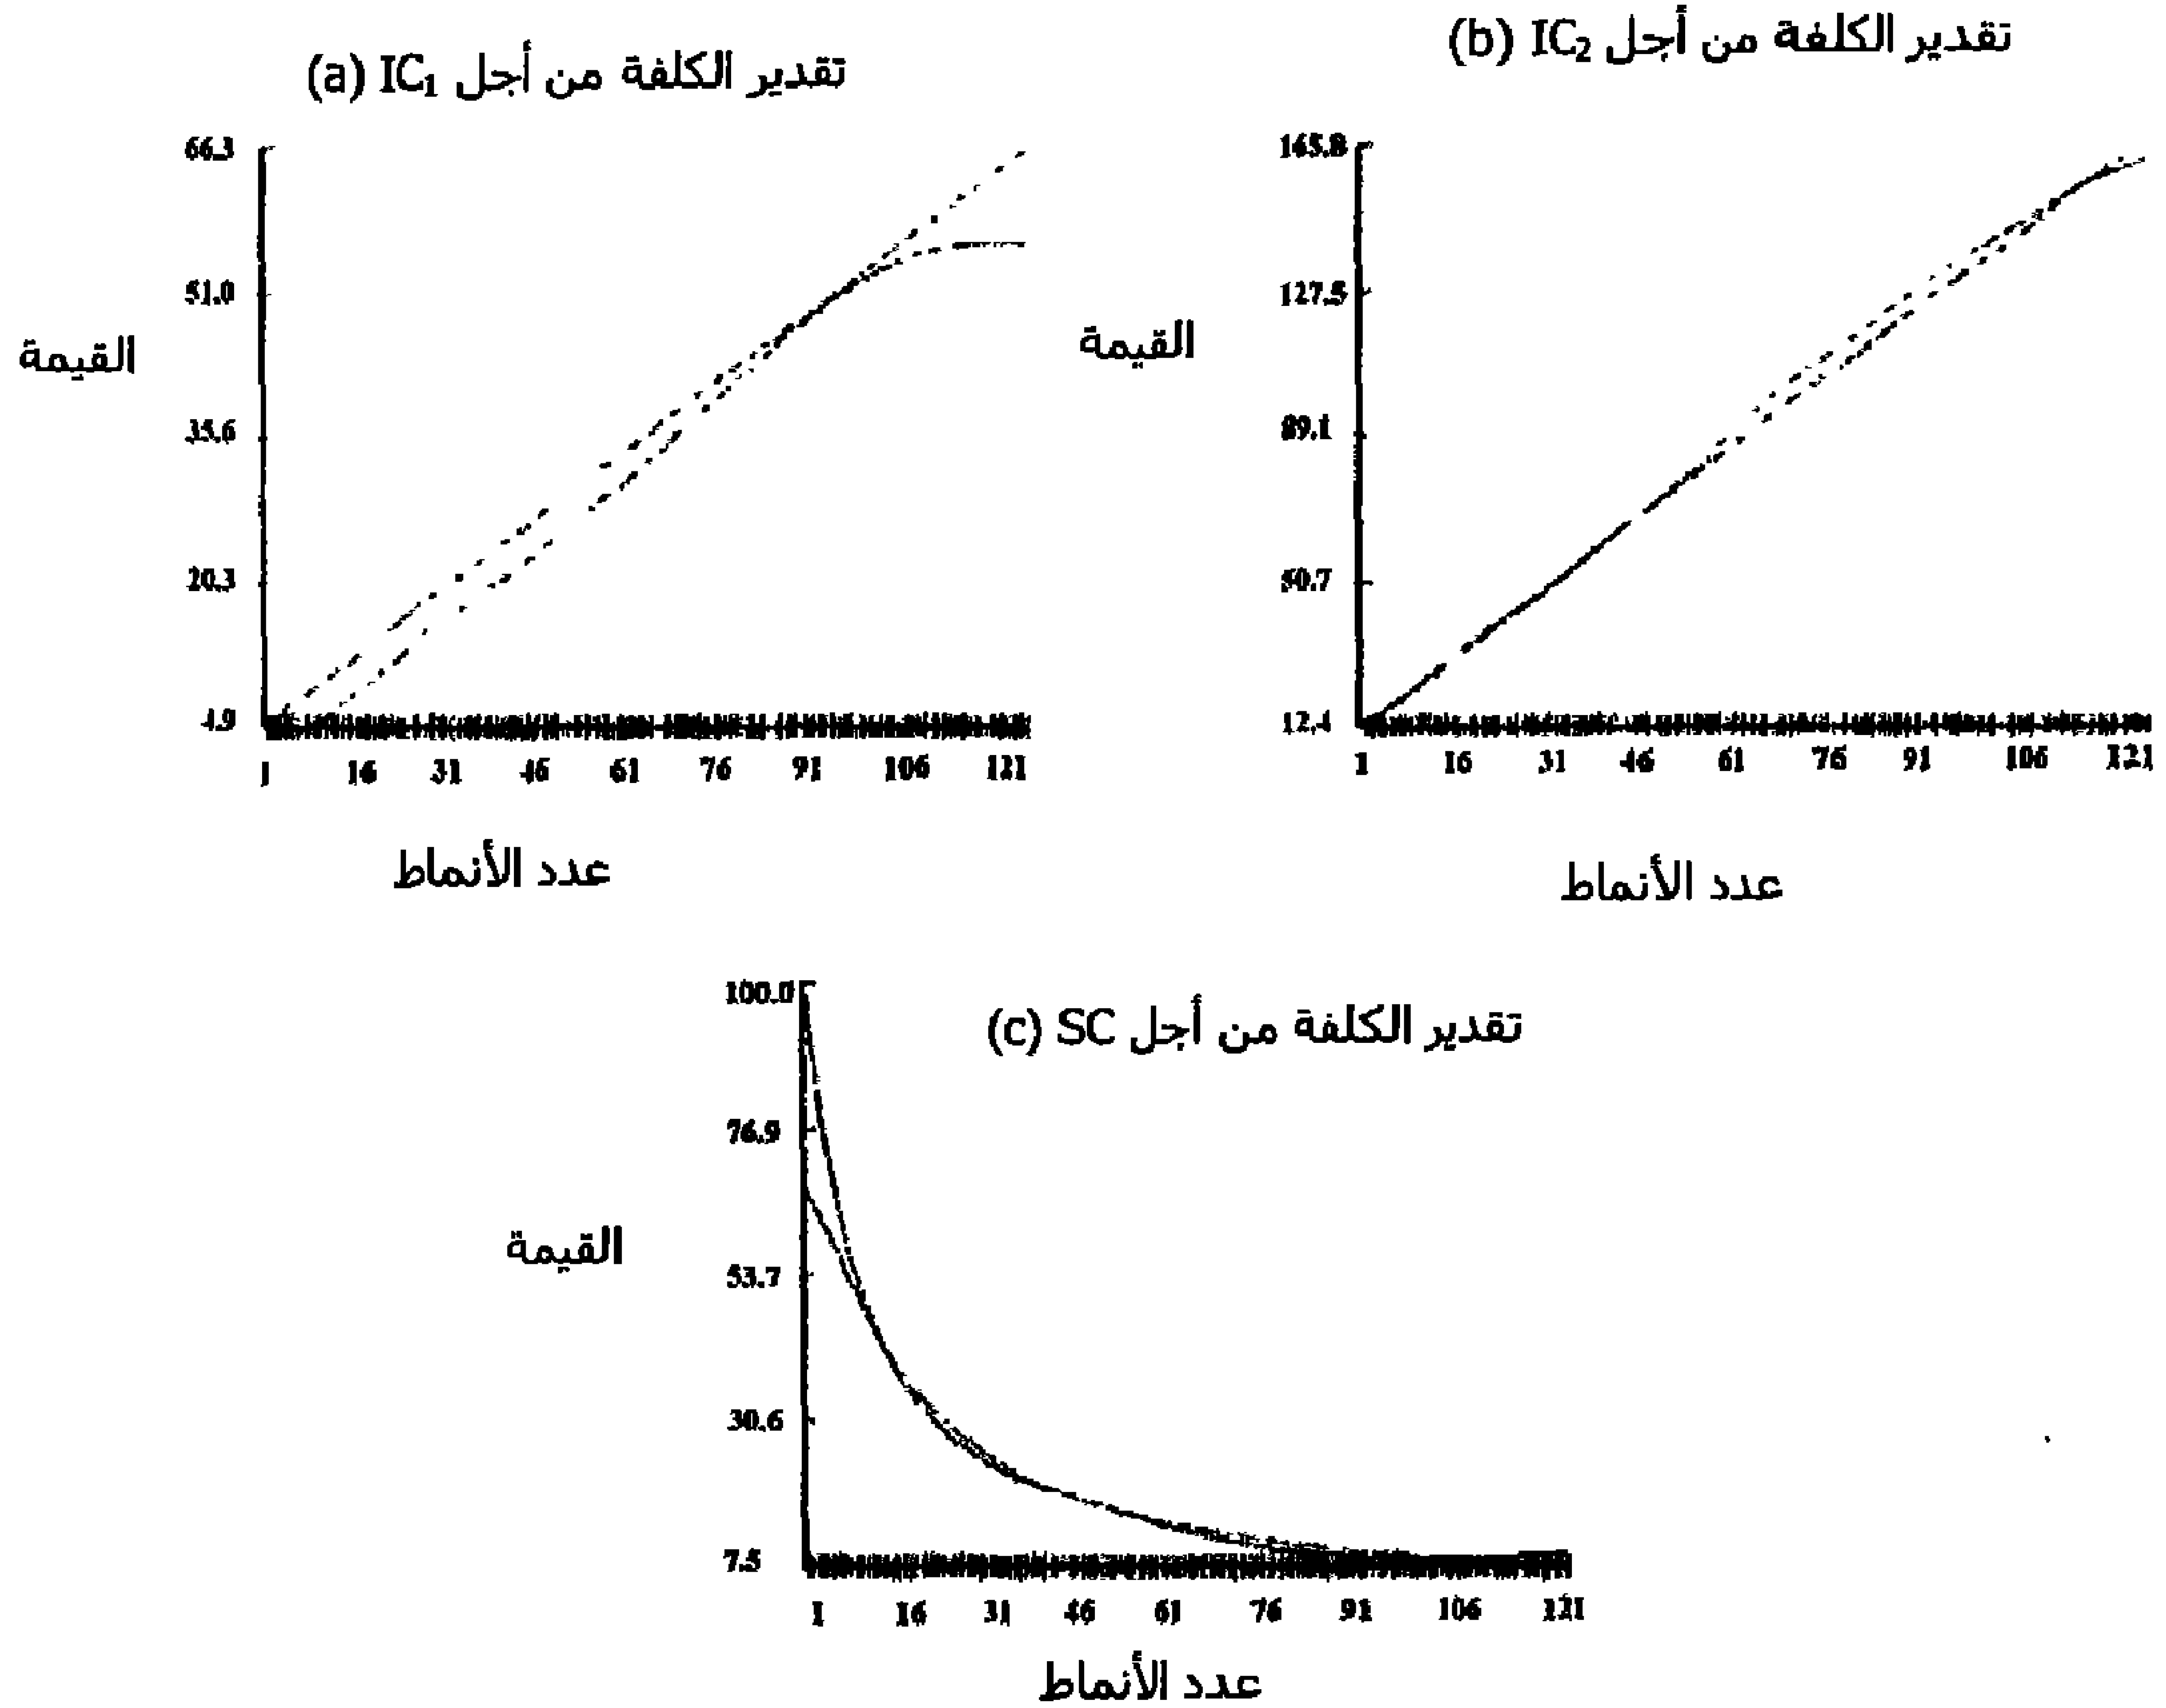
NNCTE و NNTCE

أُجريت كافة التجارب التالية باستخدام معلومات (الجدول 2). دعنا نركّز على مسألة NNTCE. طالما أن TC هي مجموع IC_1 وIC_2 وSC، فنحن بحاجة لفحص أداء الشبكات العصبونية MLP

من أجل مكّون من TC. استخدم البرنامج NeuroShell 2 (www.wardsystems.com) لتنفيذ تجارب الشبكة العصبونية MLP. حسبنا TC وفقاً للتغيرات في زمن الدورة T مفترضين نفس المتغيرات الخارجية. تم توليد مجموعة من 180 من معطيات التدريب بشكل عشوائي بتغيير بارامترات المستوى الثابت للإنتاج والمطلوب بالساعة لـــ IC وSC. طُوّر نموذج الشبكة العصبونية MLP باستخدام مجموعة 180 من المعطيات بتحديد تابع تنبؤ ملائم مقابل مجموعة معطيات اختبار غير معلومة.

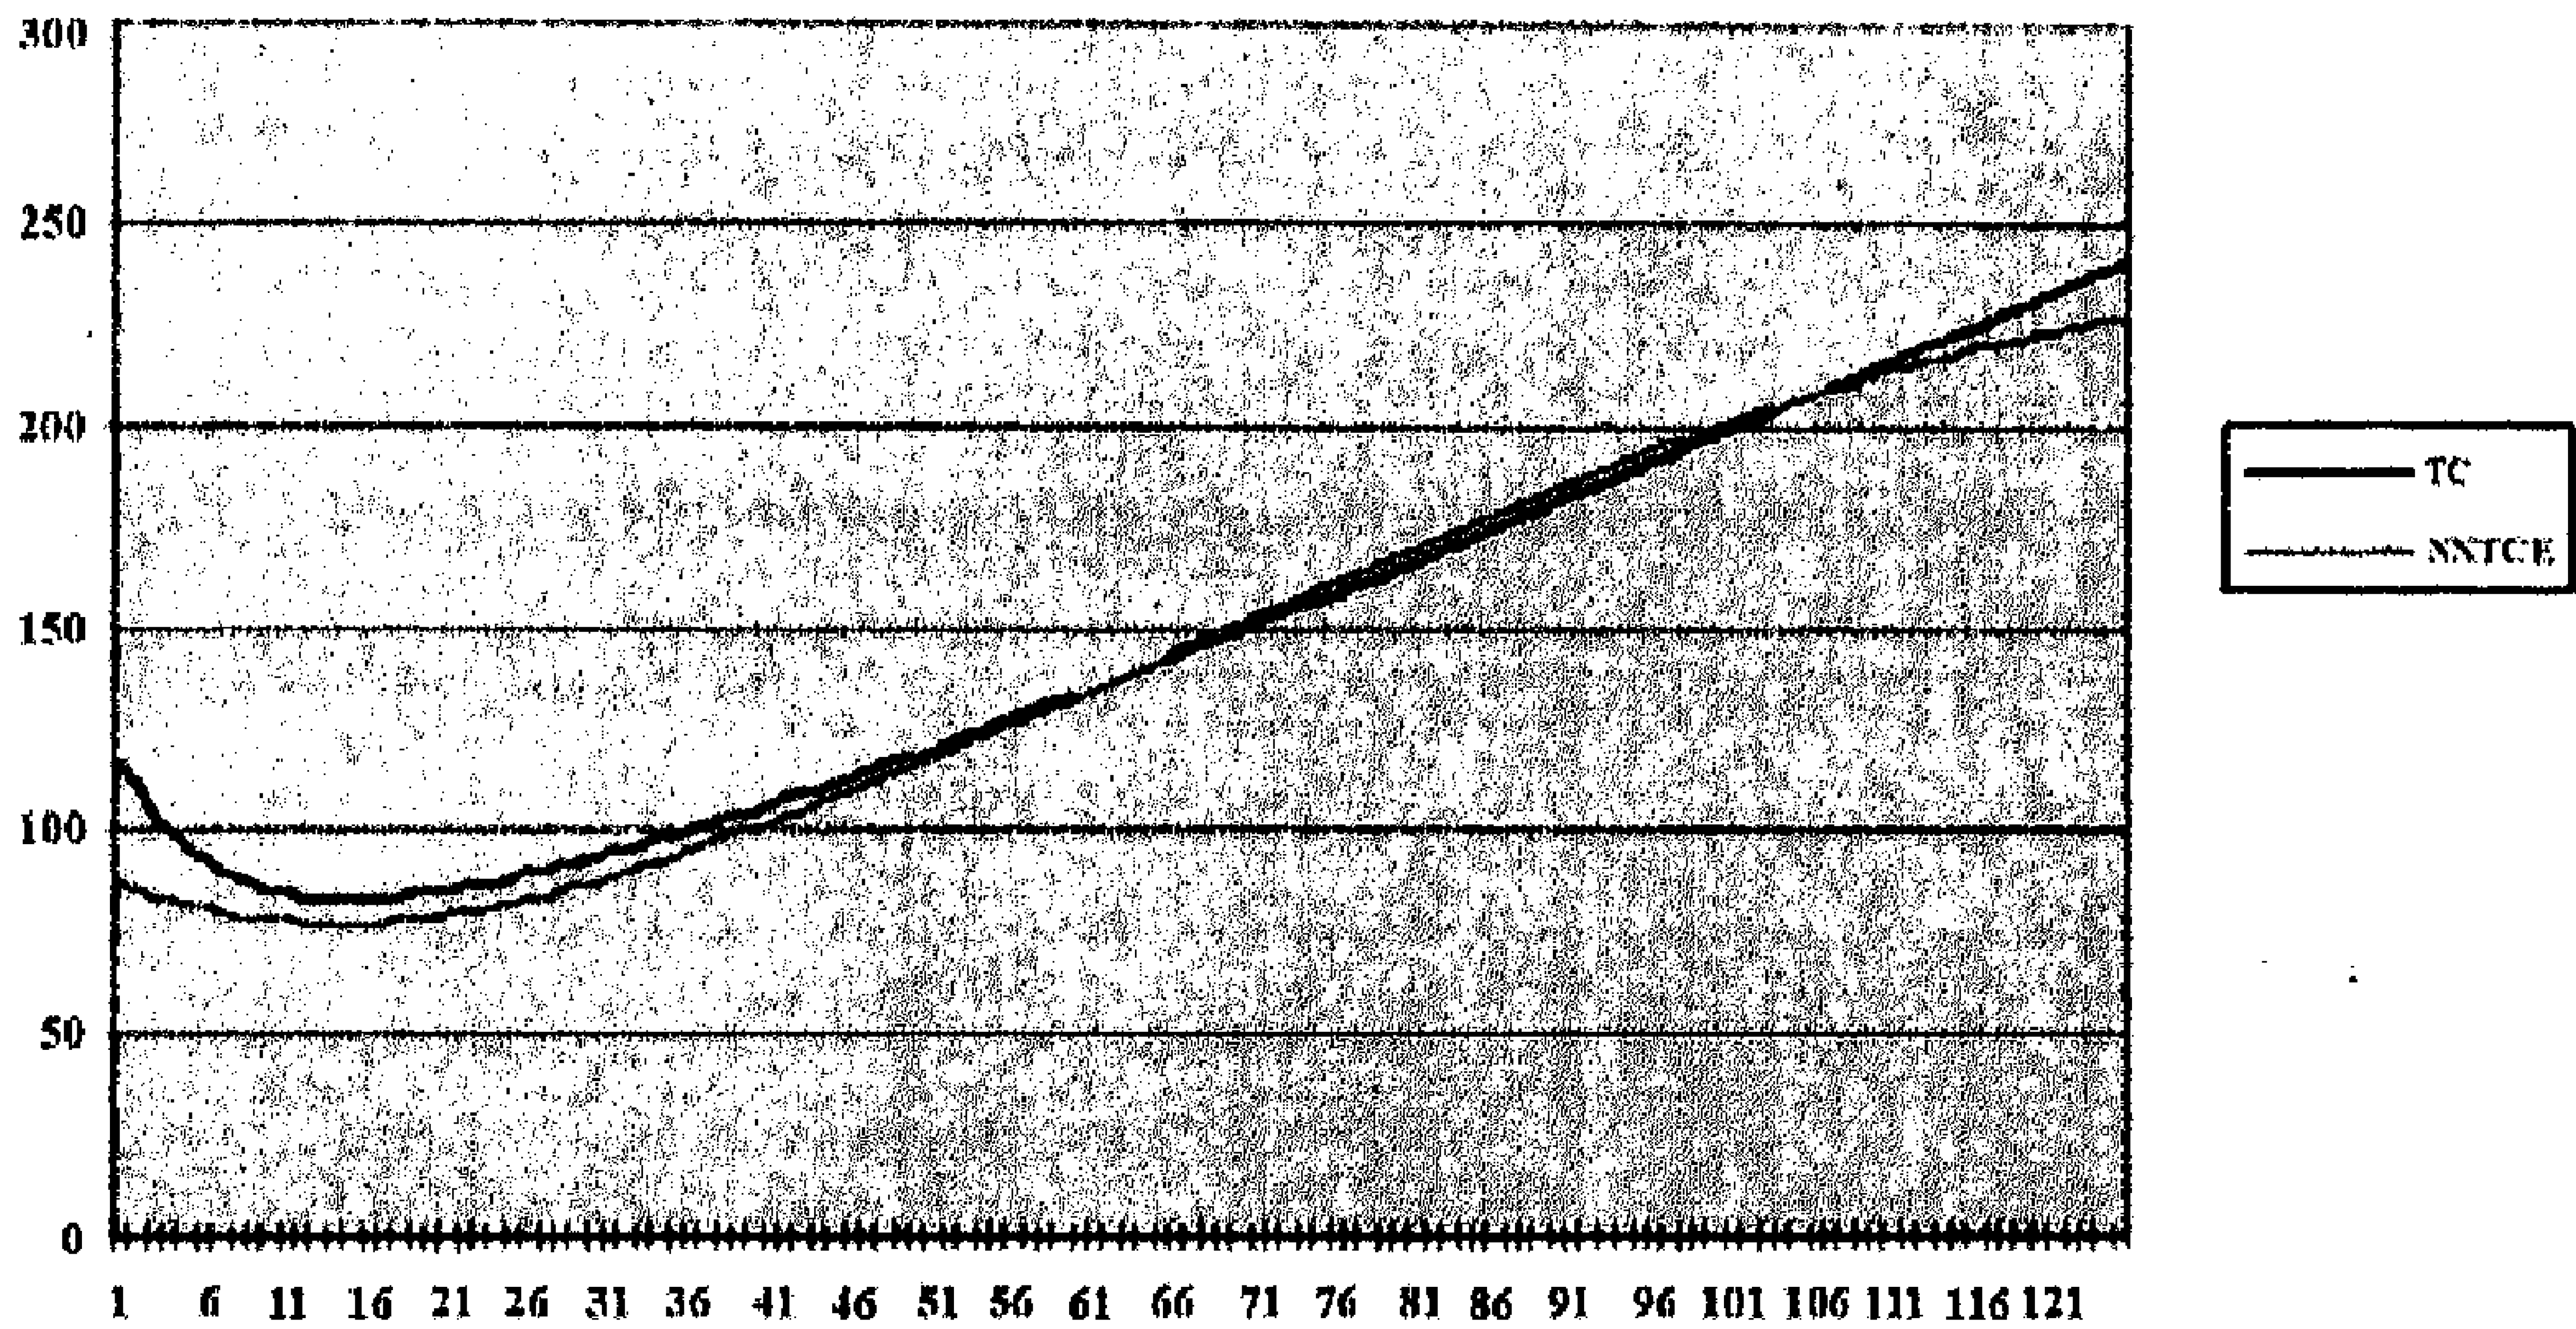
لإثبات صلاحية طريقة الشبكة العصبونية MLP، ولّدت مجموعة من معطيات الاختبار حجمها 125 بشكل عشوائي باستخدام نفس المتغيرات الخارجية (ما عدا زمن الدورة T)، بحيث استخدمت لتهيئة مجموعة التدريب. يصور (الشكل 2) تقدير الكلفة المعتمد على الشبكة العصبونية MLP من أجل IC_1 وIC_2. ويظهر SC الكلي، بأن محاكاة الشبكة العصبونية MLP تؤمن قوة تقدير كلفة كافية إلى حد ما أثناء وضع جدولة الإنتاج المعقد والمصمم من أجل هذا الفصل.

الشكل (2) *نتائج تقدير الكلفة المعتمد على الشبكة العصبونية MLP من أجل IC_1 وIC_2 و SC*



بالاعتماد على الكلف المُقدرة المبينة على (الشكل 2)، يمكن إيجاد NNTCE بجمعها. يصور (الشكل 3) نتائج TC الحقيقية مقابل NNTCE. لنناقش زمن الدورة T المُقدّر في (الشكل 3). يكون خرج NNTCE مساوياً لـ 77.106، الذي يكون عنده زمن الدورة المُقدّر هو 14. وبعبارات أخرى، يكون خرج NNCTE هو 14. على النقيض من ذلك، تكون قيمة TC هي 83.247، وزمن الدورة T هو 15. وتكون النتائج قريبة جداً من مخرجات NNTCE وNNCTE. بغية التحقق من أنه يمكن أن تُستخدم الشبكة العصبونية MLP بشكل موثوق كأداة لإنتاج قيم توكيلية من أجل TC وT، يجب علينا إجراء اختبار إحصائي.

الشكل (3) *مقارنة نتائج TC الحقيقي وNNTCE*



الاختبارات الإحصائية

نريد باستخدام طريقة الشبكة العصبونية MLP حل مسائل NNTCE وNNCTE بنجاح. إذا تم إنجاز هذا الهدف، فذلك سيعني، بأن طريقة الشبكة العصبونية MLP هي أسلوب عملي لتنفيذ ABC في حالة جدولة الإنتاج الحقيقية. بما أن طريقة الشبكة العصبونية تتطلب فقط أن تكون متغيرات الدخل والخرج محددة، فعندما يُدرب نموذج الشبكة العصبونية بشكل مناسب، يكون من السهل جداً للممارسين الحصول على نتائج NNTCE وNNCTE معقولة.

قبل استنتاج أن طريقة الشبكة العصبونية MLP تعطي نتائج NNTCE وNNCTE صالحة إحصائياً في حالات جدولة إنتاج معقدة، يتوجب مع ذلك علينا تأكيد الصلاحية الإحصائية لطريقة الشبكة العصبونية MLP لتقدير الكلفة، وتقدير زمن الدورة. أُعدّت حالات الاختبار التالية من أجل هذا الغرض:

$P = 20$

$d_1 = 9, 10, 11, 12$

$d_2 = 11, 10, 9, 8$

$m_1 = 1, 2, 3, 4, 5$

$m_2 = 6, 5, 4, 3, 2$

$SC = 40, 50, 60$

مع P ثابت لدينا 60 حالة مختلفة باعتبار أربع حالات من أجل المطلوب بالساعة (d)، وخمس حالات من أجل كلف حمل الجرد (m)، وثلاث حالات من أجل كلف الأعداد (SC). وبالتالي، يمكن أن تُقدر الكلفة TC وزمن لدورة T من أجل كلٍّ من 60 حالة مختلفة باستخدام مجموعة معطيات تدريب بحجم 180، وبمجموعة معطيات اختبار بحجم 125. باستخدام هذه الحالات الـــ 60، فإن مقارنة إحصائية وصفية لنتائج NNTCE وNNCTE مع قيم حقيقية قد لُخصت في (الجدول 3).

الجدول (3) إحصائية وصفية لنتائج NNTCE و NNCTE.

		العدد	المتوسط	الانحراف المعياري	خطأ قياسي	95% مجال ثقة للمتوسط		قيمة صغرى	قيمة عظمى
						حد أدنى	حد أعلى		
الكلفة الكلية (TC)	مُقدّر	60	80.57377	8.0838	1.043 6	78.4494	82.6259	65.78	96.20
	فعلي	60	82.0307	7.2872	.9408	80.1483	83.9132	73.32	91.65
	كلي	120	81.2842	7.7000	.7029	79.8924	82.6760	65.78	96.20
الدورة (T)	مُقدّر	60	15.20	4.36	.56	14.07	16.33	3	24
	فعلي	60	14.60	2.22	.29	14.03	15.17	12	18
	كلي	120	14.90	3.46	.32	14.28	15.52	3	14

إن نتائج NNTCE أقل قليلاً من قيم TC الحقيقية. وعلى العكس، فإن نتائج NNCTE هي أكبر قليلاً من قيم T الحقيقية. إذا كانت نتائج NNTCE و NNCTE هي فعلياً نفس قيم TC و T على الترتيب، فيمكن أن نقترح استخدام طريقة الشبكة العصبونية MLP في حالات جدولة الإنتاج.

طُبق اختبار t- من أجل هذا الغرض، والنتائج مبينة في (الجدول 4): فرضية إن نتائج NNTCE و NNCTE كانت نفس القيم TC وT الحقيقية، لم تُرفض بمستوى ثقة تحت 95%. وبالتالي، يمكن أن يُستنتج بثقة وبالصلاحية الإحصائية، بأن نتائج NNTCE وNNCTE هي عملياً قيم TC وT النظرية.

الجدول (4) نتائج اختبار -t من أجل NNTCE وNNCTE

		العدد	المتوسط	الانحراف المعياري	خطأ قياسي	95% مجال ثقة للمتوسط		قيمة صغرى	قيمة عظمى
						حد أدنى	حد أعلى		
الكلفة الكلية (TC)	مقدّر	60	80.57377	8.0838	1.0436	78.4494	82.6259	65.78	96.20
	فعلي	60	82.0307	7.2872	.9408	80.1483	83.9132	73.32	91.65
	كلي	120	81.2842	7.7000	.7029	79.8924	82.6760	65.78	96.20
الدورة (T)	مقدّر	60	15.20	4.36	.56	14.07	16.33	3	24
	فعلي	60	14.60	2.22	.29	14.03	15.17	12	18
	كلي	120	14.90	3.46	.32	14.28	15.52	3	14

تعليقات ختامية

من المعلوم جيداً، بأن مدراء الكلفة الذين يريدون التحكم بالكلفة الكلية، وزمن الدورة بمستويات صغرى في جدول إنتاج محدد، قد أُغروا بتطبيق ABC في مواقع حقيقية. مع ذلك، فقد أُحبط الكثير من مدراء الكلفة نتيجةً للصعوبات التقنية، بالإضافة للتعقيدات النظرية لـــ ABC. تقترح هذه الدراسة طريقة بسيطة ولكن قوية لحل هذه القضية بتطبيق نموذج الشبكة العصبونية MLP.

قد يبدو تطبيق إطارات عمل نظرية معقدة بغية التحكم بالكلفة في جدول إنتاج محدد مماثل لكثير جداً من التحديات لصانعي القرار، الذين يتوجب عليهم مراقبة عمليات التصنيع على أساس الزمن الحقيقي. غير أنه ليس لديهم خيار سوى الاعتماد على مثل هذه النظريات، إذا أرادوا تشغيل وسائل التصنيع بشكل صحيح. نظمت هذه الدراسة مسألتين فرعيتين لـــ NNTCE وNNCTE لتحديد فيما إذا بإمكان طريقة الشبكة العصبونية MLP لتوقع الكلفة الكلية، وزمن الدورة في حالة جدولة الإنتاج، أن تعطي إحصائياً نتائج مماثلة للكلفة الكلية الحقيقية وزمن الدورة الحقيقي. إذا أنتجت الشبكة العصبونية MLP الكلفة الكلية المقدرة وزمن الدورة المقدّر، بحيث تكون فعلياً نفس القيم المثالية، التي يمكن الحصول عليها بتطبيق نماذج معقدة، يمكن عندئذ لمدراء الكلفة في منظمات التصنيع، أن يتخلصوا من الكفاح بالتقنيات المتطورة لإبقاء الكلفة الكلية في المستويات الدنيا المعقولة. تظهر النتائج الإحصائية، بأن طريقة الشبكة العصبونية MLP قادرة على تأمين برنامج دعم قرار أمين ومتين لصانعي القرار، الذين يريدون تخفيض الكلف إلى الحد الأدنى أثناء التصنيع الحقيقي.

المراجع

Andrea, M.C., Pilho, R.C.P., Espozel, A.M., Maia, L.O.A., & Quassim, R.Y. (1999). Activity-based costing for production learning. International Journal of Production Economics, 62, 175-180.

Babad, Y.M., & Balachandran, B.V. (1993). Cost driver optimization in activity-based costing. The Accounting Review, 65(3), 563-575.

Bell, T. B., Ribar, G.S., & Verchio, J. (1990). Neural nets versus logistic regression: A comparison of each model's ability to predict commercial bank failures. In R.P. Srivastava (Ed.), Proceedings of the 1990 Deloitte and Touche/University of Kansas Symposium of Auditing Problems, Lawrence, KS (pp. 29-58).

Bode, J. (1998a). Neural networks for cost estimation. Cost Engineering, 40(1), 25-30.

Bode, J. (1998b). Decision support with neural networks in management of research and development: Concepts and application to cost estimation. Information and Management, 34(1), 33-40.

Boothroyd, G., & Reynolds, C. (1989). Approximate cost estimates for typical turned products. Journal of Manufacturing Systems, 8(3), 185-193.

Cooper, R., & Kaplan, R.S. (1988a). Measure costs right: Make the right decisions. Harvard Business Review, 65(5), 96-103.

Cooper, R.,& Kaplan, R.S. (1988b). How cost accounting distorts product cost. Management Accounting, (April), 2002.

Creese, R.C., & Li, L. (1995). Cost estimation of timber bridges using neural networks. Cost Engineering, 37(5), 17-22.

Duverlie, P., & Castelain, J.M. (1999). Cost estimation during design step: Parametric method versus case based reasoning method. International Journal of Manufacturing Technology, 15, 895-906.

Etheridge, H.L., & Sriram, R.S. (1997). A comparison of the relative costs of financial distress models: Artificial neural networks, logit and multivariate discriminant analysis. Intelligent Systems in Accounting, Finance, and Management, 6, 235-248.

Etheridge, H.L., Sriram, R.S., & Hsu, K. (2000). Artificial neural networks help auditors evaluate client financial viability. Decision Sciences, 31(2), 531-549.

Fanning, K., & Cogger, L.O. (1994). A comparative analysis of artificial neural networks using financial distress prediction. Intelligent Systems in Accounting. Finance, and Management, 3(4), 241-252.

Garza, J.M., & Rouhana, K.G. (1995). Neural networks versus parameter based applications in cost estimating. Cost Engineering, 37(2), 14-18.

Gunasekaran, A., & Sarhadi, M. (1998). Implementation of activity-based costing in manufacturing. International Journal of Production Economics, 56-57, 231-242.

Haedicke, J., & Feil, D. (1991). In a DOD environment: Hughes aircraft sets the standard for ABC. Management Accounting, 72(8), 29-33.

Hodby, T., Thomson, J., & Sharman, P. (1994). Activity-based management at AT&T. Management Accounting, 75(10), 35-39.

Horngren,C.T., Foster, G., & Datar,S.(1997). Cost accounting: Amanagerial emphasis. NJ: Prentice-Hall.

Kee,R., & Schmidt,C. (2000). A comparative analysis of utilizing activity-based costing and theory of constraints for making product-mix decision. International Journal of Production Economics, 63, 1-17.

Kiritsis, D., Neuendorf, K.P., & Xiruchakis, P. (1999). Petri net techniques for process planning cost estimation. Advances in Engineering Software, 30, 375-387.

Koltai, T., Lozano, S., Guerrcro, P., & Onieva, L. (2000). A flexible costing system for flexible manufacturing systems using activity based costing. International Journal of Production Research, 38(7), 1615-1630.

Lee, K.C., & Oh, S.B. (1996). An intelligent decision support approach to time series identification by a neural network-driven decision tree classifier. Decision Support Systems, 17, 183-197.

Levitan, A., & Gupta, M. (1996). Using genetic algorithms to optimize the selection of cost drivers in activity-based costing. International Journal of Intelligent Systems in Accounting, Finance and Management, 5(3), 129-145.

Lewis, R.J., (1995). Activity-based models for cost management systems. Westport, CT: Quorum Books.

Liang, T. P., Chandler, J.S., Han, L., & Roan, J. (1992). An empirical investigation of some data effects on the classification accuracy of probit, ID3, and neural networks. Contemporary Accounting Research, 9(1), 306-328.

Luong, L.H.S., & Spedding, T. (1995). An integrated system for process planning and cost estimation in hole making. International Journal of Advanced Manufacturing Technology, 10, 411-415.

Merz, C.M., & Hardy, A. (1993). ABC puts accountants on design team at HP. Management Accounting, 75(3),22-27.

Miller, S.H. (1994). The view from inside: GM's general auditor looks back. Journal of Accountancy 177(3), 44-46.

Montagno, R., Sexton, R.S., & Smith, B.N. (2002). Using neural networks for identifying organizational improvement strategies. European Journal of Operational Research, 142(2), 3S2-395.

Park, C.C., & Kim, G.T. (1995). An economic evaluation model for advanced manufacturing system using activity-based costing. Journal of Manufacturing Systems, 14(6), 439-451.

Porter, T.J., & Kehoe, J.G. (1994). Using activity-based costing and value analysis to take the pain out of downsizing at a naval shipyard. National Productivity Review,13(1), 115-125.

Rumelhart, D.E., Hinton, G.E., & Williams, R.J. (1986). Learning internal representations by error propagation. In D.E. Rumelhartand & J.L. McClelland (Eds.), Parallel distributed processing: Exploration in the microstructure of cognition. Cam-bridge, MA: MIT Press.

Schniederjans, M.J., & Garvin, T. (1997). Using the analytic hierarchy process and multi-objective programming for the selection of cost drivers in activity-based costing. European Journal of Operational Research, 100(1), 72-80.

Sexton, R.S., Sriram, R.S., & Etheridge, H. (2003). Improving decision effectiveness of artificial neural networks: A modified genetic algorithm approach. Decision Sciences, 34(3), 421-442.

Smith, A.E., & Mason, A.K. (1997). Cost estimation predictive modeling: Regression versus neural network. The Engineering Economist, 42(2), 137-160.

Soloway, L.J. (1993). Using activity-based management systems in aerospace and defense companies. Journal of Cost Management, 6(4), 56-66.

Spedding, T.A., & Sun, G.Q. (1999). Application of discrete event simulation to the activity based costing of manufacturing systems. International Journal of Production Economics, 58, 289-301.

Surkan, A.,& Singleton, J.(1990). Neural networks for bond rating improved by multiple hidden layers. International Joint Conference on Neural Networks, San Diego, CA(vol.2, pp. 157-162).

Takakuwa.S. (1997, December 7-10). The use of simulation in activity-based costing for flexible manufacturing systems. Proceedings of the 1997 Winter Simulation Conference, Atlanta, GA (pp.793-800).

Tam, K.Y., & Kiang, M.Y. (1992). Managerial applications of neural networks: The case of bank failure predictions. Management Science, 38(7), 926-947.

Tsai, W.-H. (1996). Activity-based costing model for joint products. Computer and Industrial Engineering, 31 (3/4), 725-729.

Yang, Y.N., Parsaei, H.R., Leep, H.R., & Wong, J.P. (1998). A manufacturing cost-estimation system using activity-based costing. International Journal of Flexible Automation and Integrated Manufacturing, 6(3), 223-243.

الفصل الخامس عشر

كشف التدخل باستخدام التقنيات الحديثة: تكامل الخوارزميات الوراثية والمجموعات الخشنة مع الشبكات العصبونية

ملخص

يصبح نظام كشف التدخل أو الاقتحام (IDS) الآن جزءاً مكملاً من البنية التحتية لأمن الشبكة. تُستخدم أدوات التنفيذ في المعطيات على نحو واسع من أجل تطوير IDS. على أية حال، يتطلب هذا قدرة لإيجاد النقل من فضاء الدخل إلى فضاء الخرج بمساعدة المعطيات المتوفرة. المجموعات الخشنة والشبكات العصبونية هي أدوات التنقيب في المعطيات الأفضل المعروفة لتحليل المعطيات والمساعدة في حل هذه المسألة. يقترح هذا الفصل طريقة هجينة جديدة لتكامل نظرية المجموعات الخشنة والخوارزمية الوراثية (GA)، والشبكة العصبونية الصنعية. تتألف طريقتنا من مرحلتين: أولاً، تُطبق نظرية المجموعات الخشنة لإيجاد مجموعة المعطيات المُخفضة. ثانياً، تُستخدم النتائج كمدخلات للشبكة العصبونية، حيث تُستخدم طريقة تعلّم معتمدة على GA لتدريب نظام كشف التدخل. لا تُميّز الطريقة فقط باستخدام تخفيض الخاصية كتقنية معالجة أولية للشبكة العصبونية الصنعية، وإنما أيضاً بخوارزمية تعلّم مُحسّنة. تم تبيان عملياً كفاءة وفعالية الطريقة المقترحة على معطيات كأس KDD.

مقدمة

تؤسس الآن الحاجة لأنظمة شبكات مأمونة. مع الاستخدام الواسع للانترنت وشبكات الحاسوب الأخرى، تعتمد التجارة الالكترونية واتصالات المعطيات على الشبكات الآمنة، لقد اعتنقت المنظمات تقنية المعلومات للاشتراك في المعلومات، وتطوير عملها. وهذا ما يجعل امتلاك الشبكات، التي تعمل بكفاءة ووثوقية أمراً ملحاً. إن أسلوب العمل الالكتروني للعملية ضروري للمنظمات المعاصرة العالمية. وقد جلب ذلك معه أيضاً التأثير غير المرغوب للاختراقات الأمنية.

إن نظام كشف التدخل الجيد (IDS) هامٌ لضمان بقاء أنظمة الشبكة. يعتمد كشف التدخل على حقيقة، أن سلوك الدخيل سيكون مختلفاً بشكل ملحوظ عن المستخدم الشرعي.

يتزايد عدد التدخلات بشكل مثير، وكذلك الكلف المرتبطة بها. فلقد تم الإبلاغ عن عدد من الحوادث إلى فريق استجابة طوارئ الحاسوب Carnegie Melon/مركز الإحداثيات (CERT/CC) قد ازداد من المجال 2000 إلى 3000 في أول ومنتصف التسعينات (1990s)، إلى 52658 في عام 2001، وإلى 82094 في عام 2002، و137529 في عام 2003. كما يُذكر أيضاً بأن الجريمة الالكترونية كلفت المنظمات حوالي 666 مليون دولار في عام 2003. تُظهر المعطيات المنشورة من قبل مكتب المحاسبة العامة الأمريكية حوالي 25000 محاولة لمهاجمة النظام، وقد تم اكتشاف من 1 إلى 4% فقط من تلك المحاولات.

يمكن أن يستخدم التنقيب في القواعد على قواعد معطيات كبيرة، لتوليد خوارزمية تعلّم لاكتشاف الهجوم على الموقع. تمتلك هذه الطريقة دفعة ضخمة من تطبيقات العمل العديدة مثل التجارة الالكترونية، والأنظمة المفوضة، وإدارة سلسلة الدعم، وأنظمة دعم قرار مجموعة ما... الخ.

تساعد IDS مدراء الشبكة للاستعداد والتعامل مع هجمات أمن الشبكة، فهي تجمع المعلومات من تشكيلة من الأنظمة والمصادر شبكية، التي تُحلّل بعد ذلك من أجل إشارات التدخل وسوء الاستعمال. إن تحديد الطريقة الملائمة مهم في تدخل الشبكة، بما أن الأداء من ناحية دقة الكشف، ومعدل الإنذار الكاذب، وزمن الكشف يصبح حاسماً من أجل المراقبة القريبة في الزمن الحقيقي. يمثل التنقيب في المعطيات تقنية مفيدة جداً لاستخلاص معلومات ذات مغزى، وتحسين عمليات اتخاذ القرار. تُنقى المعلومات المستخلصة لكسب المعرفة المفيدة، التي تُستخدم فيما بعد لتنبؤ، وتصنيف، ونمذجة، وتلخيص المعطيات التي نُقبت. إن حث القواعد، والشبكات العصبونية، والخوارزميات الوراثية، والمنطق الغامض، والمجموعات الخشنة هي تقنيات تنقيب في المعطيات مستخدمة على نحو واسع من أجل التصنيف الصناعي، وتمييز الأنماط، والأشكال. ويمكن أن يُمثل خرج IDS كما هو مبين في (الجدول 1).

الجدول (1) خرج IDS.

التنبؤ IDS		الحقيقة	
		هجوم	لا هجوم
	هجوم	مكتشف	إنذار كاذب
	لا هجوم	غير مكتشف	تنبؤ صحيح

يمكن أن يُصنّف المرور إلى موقع ما بشكل واسع إلى طبيعي وشاذ. نشير إلى المرور الشاذ هنا على أنه هجوم. يقيم أي نظام IDS كامل حركة المرور، وتصنّفها كطبيعية أو هجوم. الكشف

الصحيح لحالة هجوم ما هو أكثر أهمية من حالة طبيعية صُنّفت كهجوم. لذا، يكون التأكيد هنا على الكشف الصحيح للهجمات، بينما يتم الإبقاء على الإنذارات الكاذبة ضمن مستوى معقول.

بغية تطوير آليات أمن ودفاع أفضل ضد هجمات الشبكة، من المهم تقصي أنماط الهجمات على أنظمة ومواقع الشبكة. لقد أظهرت تقنيات التنقيب في المعطيات نتائج واعدة، عندما طُبقت على مثل هذه المشاكل. نبني في هذا الفصل طرقاً موجودة من DS، ونقيم إمكانية تطبيق الشبكات العصبونية الصنعية والمجموعات الخشنة لأغراض كشف التدخل. يُبنى نموذج هجين بدمج المجموعات الخشنة مع الشبكات العصبونية باستخدام طبيعتها التكميلية. تُستخدم المجموعة الخشنة كأداة معالجة أولية لإزالة المعطيات الفائضة من قاعدة المعطيات الضخمة. وهذا يقلل زمن تعلّم الشبكة العصبونية. تُحسّن تغيرات التغلب على الحد الأدنى المحلي بالدخول للتعلم المعتمد على الخوارزمية الوراثية (GA)، الذي يزيد دقة تنبؤها.

الغرض من هذا الفصل هو تطوير شبكة عصبونية ومجموعات خشنة للتنقيب عن قواعد من مجموعات المعطيات الكبيرة. تُستعمل وجهة النظر المكتسبة بتطوير نظام هجين معتمد على الطريقة العصبونية الخشنة، وأُظهرت الكفاءة على معطيات كأس KDD. مساهمات هذه الدراسة هي التالية:

1. تخفيض الخواص من جدول القرار باستخدام المجموعات الخشنة.
2. طريقة عصبونية خشنة لتصنيف التدخل.
3. مقارنة إحصائية المتوسطات والانحرافات المعيارية من أجل تقنيات التنقيب في المعطيات المذكورة.

يُنظم هذا الفصل كالتالي. نزود أولاً مسح للمادة المنشورة مُتبع بنموذج هجين من أجل IDS، الذي يستخدم GA للتعلّم. بعد ذلك، تُقدم أساسيات المجموعات الخشنة كأداة تنقيب في المعطيات. ويُوضحّ ذلك أيضاً بتطبيقها على IDS. لتحسين كفاءة IDS، تم استكشاف المؤزرات بين الشبكة العصبونية والمجموعات الخشنة، وقدمت نفسها في طريقة عصبونية – خشنة. بعدئذ، نقدم كفاءة الطريقة المقترحة في قسم النتائج والمناقشة، وأخيراً نستنتج بإعطاء اتجاهات من أجل البحث المستقبلي.

المادة المنشورة

إن الأنظمة المُشبّكة كبيرة الحجم المعاصرة، التي تُوزّع إلى حد كبير تحسن فعالية وكفاءة المنظمات بالسماح لمستويات مختلفة من التكامل التنظيمي. على أية حال، يكون مثل هذا

التكامل مصحوباً بالأخطار المرتفعة للتدخل والمساومة. يمكن أن يحد دمج IDS إلى أنظمة المنظمات من هذه الأخطار. إن المادة المنشورة في مجال IDS غنية جداً. نركزّ في هذا الفصل على استخدام تقنيات التنقيب في المعطيات من أجل IDS.

وسيكون تركيزنا عملياً على الشبكات العصبونية، والخوارزميات الوراثية، والمجموعات الخشنة.

إحدى الطرق الفعّالة لتحسين أمن الشبكة هي استخدام نظام كشف تدخل كفوء (Garfinkel & Spafford, 1991; Russel & Gangeni, 1991). تجمع IDS المعلومات من تشكيلة من الأنظمة ومصادر الشبكة، ومن ثم تحلّل النظام من أجل إشارات التدخل وسوء التعامل. والوظائف الرئيسية المُنفذة بواسطة أي IDS هي التالية.

1. مراقبة وتحليل المُخدّم.
2. تقييم سلامة الأنظمة الحرجة.
3. تمييز الهجمات المعروفة بواسطة أنماط النشاط.
4. الاستجابة آلياً للنشاط المُكتشف.
5. تقديم تقرير عن نتيجة عملية الكشف.

تعريف حدسي من أجل نظام حاسوب آمن هو التالي: "يكون أي نظام حاسوب آمناً، إذا كان باستطاعته الاعتماد على السلوك كما هو متوقع له" (Garfinkel & Spafford, 1991). وبشكل رسمي أكثر، يُعرّف الأمن غالباً من ناحية السرية، والسلامة، وإمكانية الاستفادة (Russel & Gangeni, 1991). التدخل في شبكات الحاسوب هو عدم قدرة الشبكة للعمل بكفاءتها العالية، ويمكن أن يُعرّف أي تدخل "كأي مجموعة من الأعمال، تحاول تسوية السلامة أو السرية أو إمكانية توفر المصادر" (Heady, Luger, Maccabe, & Servilla, 1990).

يوجد أنواع مختلفة من التدخلات على الشبكات. أي مستخدم مُشغّل لبرنامج ما، ينفذ أعمالاً زائدة عما هو مرخص له، يقوم بنوع من التدخل. والمستخدم، الذي يزيد تحميل النظام، ويمنع مستخدمين آخرين من استعمال النظام، يقوم بنوع آخر من التدخل ويصطلح على تعريفه كهجوم رفض الخدمة. لقد أصبح الكشف وتقديم تقرير التدخل مهمة هامة جداً. يمكن أن تصنّف طرق كشف التدخل على نحو واسع إلى فئتين:

كشف الشذوذ: تنمذج خوارزمية كشف الشذوذ عن السلوك الطبيعي. تقارن نماذج كشف الشذوذ معطيات حساس حركة مرور الشبكة مع أنماط طبيعية معلّمة من معطيات التدريب. إذا انحرفت معطيات الحساس عن السلوك الطبيعي، تُصنّف نموذج كشف الشذوذ المعطيات كأنها

نشأت عن هجوم. تتطلب غالبية هذه الخوارزميات، بأن تكون المعطيات المستخدمة للتدريب طبيعية تماماً، ولا تحتوي على أي نوع من الهجمات.

كشف سوء الاستعمال: تشكل خوارزميات سوء الاستعمال سلوك هجوم معروف، فهي تقارن معطيات الحساس عن حركة مرور الشبكة مع أنماط هجوم مُعلّمة من معطيات التدريب. إذا طابقت معطيات الحساس نمط بعض معطيات الهجوم المعروفة، فعندما يُعتبر المرور المرصود تدخلياً. يتم الحصول على نماذج سوء الاستعمال نموذجياً بالتدريب على مجموعة كبيرة من المعطيات، التي اُعتبرت الهجمات فيها.

لذا، من أجل الكشف والمبدع عن التدخلات، يجب أن يكون لدى أي نظام نوع من IDS المركبة. "يجب أن تتعرف أي IDS – ومن المفضل بالزمن الحقيقي – على الاستخدام غير المُخوّل وسوء الاستعمال، وسوء استخدام أنظمة الحاسب" (Mukherjee, Heberline & Levitt, 1994).

توجد تقنيتان واسعتان لأمن الشبكة هما: الحماية والكشف (Lunt, 1993). تحاول تقنية الحماية حماية النظام من الهجوم، وأداة الحماية المستعملة الأكثر شيوعاً هي جدار النار، الذي يسمح للمعطيات الصحيحة فقط بالمرور عبره. أما الطريقة الأخرى فهي باستخدام IDS، الذي يجمع المعلومات من تشكيلة من الأنظمة ومصادر الشبكة، ويحلل تدفق المعلومات للإشارة إلى التدخلات أو سوء الاستعمال. وكانت نمذجة IDS دائماً مسالة هامة للباحثين في هذا الحقل. يقترح الباحث Denniny (1987) نموذج IDS معتمداً على معطيات تاريخية، ويقدم الباحث Lunt (1993) مسحاً مفصلاً للأعمال المُنفذة على هذا الموضوع. يُقاس نجاح أي IDS بالإيجابيات الخاطئة والإيجابيات الصحيحة.

لقد أظهر الباحثون بأن فعالية أي IDS يمكن أن تُحسّن باستخدام تقنيات التنقيب في المعطيات. يقدم الباحثون Lee, Stolfo, & Mok (1999) نموذجاً معتمداً على التنقيب في المعطيات، يستقصي الباحثون Chebrolu, Abraham, and Thomas (2004) أداء تقنيات التنقيب في المعطيات ويقترحون تقنية معتمدة على شبكة Bayes. قارن الباحثون Zhang, & Chu, Permkumar, Zhu (2001) تقنيات تنقيب في المعطيات مختلفة، ووجدوا أن الشبكات العصبونية هي الأفضل في التعرف على الاتصالات الخبيثة. يطبق الباحثون Cansian, and Carvalho, Bonifacio (1997) شبكات عصبونية لنمذجة أي IDS. ويصرح الباحثان Lippmann & Cunningham (2000) بأن فعالية أي IDS تتحسن باستخدام الشبكات العصبونية. إن غالبية أنظمة كشف التدخل ببنية متعددة المستويات، يمكن أن تكشف فقط إما سوء الاستعمال أو هجمات الشذوذ. اُقترحت بعض IDS مع بنية متعددة المستويات، أو مع مُصنفات متعددة لكشف كلا الهجومين. وطوّرت شبكة عصبونية متسلسلة هرمياً متعددة المستويات من قبل الباحثين Zhang, Jiang, & Mohamed (2004)

تفيد من أجل التعلم التكّيفي. يُصر الباحثون Joo, Hong, & Han (2003)، بأن الشبكات العصبونية تناسب هذا المجال. ولكن المشكلة الرئيسية مع الشبكات العصبونية هي أن عملية التدريب تستهلك زمناً كثيراً وقوة معالجة كبيرة بسبب خوارزمية التعلّم المعتمدة على التدرج (Hassoum, 1998).

من بين الشبكات العصبونية العديدة المُقدمة في المادة المنشورة، ربما تكون الشبكة العصبونية أمامية الانتشار بخوارزمية تعلم خلفية الانتشار الأكثر شعبيةً والأوسع استخداماً. وهي تستخدم تعلّماً مُراقباً، حيث تُدرّب الشبكة باستخدام المعطيات، التي تكون من أجلها المدخلات، بالإضافة إلى المخرجات، معلومة. تستخدم طريقة الانتشار الخلفي خوارزمية هبوط التدرج لتخفيض الخطأ على معطيات التدريب إلى الحد الأدنى بانتشار الأخطاء خلفاً من خلال البدء بالشبكة عند وحدات الخرج، والعمل للخلف باتجاه وحدات الدخل. وعندما طُبقت على معطيات دخل، وُجدت فرص عالية لمقاربتها القيمة صغرى محلية وليس قيمة صغرى عامة. كما يتطلب أيضاً الانتشار الخلفي حساب الاشتقاقات من أجل الاتجاه التدرجي، الذي يجب أن يكون مستمراً قابلاً للاختلاف، وغير متناقص، وقابلاً للحساب بسهولة. تعتمد شبكة الانتشار الخلفي إلى حد كبير على اختيار معدل التعلّم، وثابت تناسب الزخم. لم يحصل الباحث Zhu et at. (2001) على نتائج مشجعة بتطبيق الشبكة العصبونية خلفية الانتشار القياسية من أجل كشف التدخل. وبسبب الصعوبات المُصادفة، يكون من الأفضل اختيار خوارزمية تعلّم معتمدة على التدرج. تمتلك الطريقة المقترحة للتعلّم المعتمد على GA للشبكات العصبونية ميزة إضافية لطبيعية التكيّف الذاتية، وأيضاً سرعة تقارب متزايدة.

كما استخدمت أيضاً GA من أجل نمذجة أي IDS. إن مفهوم GA معطى من قبل الباحث Holland (1975) ويُستخدم بنجاح كطريقة أمْثَلة من قبل الباحث Goldberg (1989). لقد تم إثبات أن GAs كأداة أمْثلة وتنقيب في المعطيات فعالة. يستخدم الباحثان Balajinath & Raghavan (2001) الخوارزميات الوراثية من أجل تعلّم سلوك مستخدم الحاسوب. ويستخدم الباحثان Crosbie & Spafford (1995) البرمجة الوراثية المعتمدة على الاقتراحات من Koza (1992)، وحقق نتائج جيدة.

كان استنتاج القواعد دائماً مشكلة مع تقنيات التنقيب في المعطيات المعتمدة على الشبكات العصبونية. إن نظرية المجموعات الخشنة المُقدمة من قبل الباحث Pawlak (1982) هي تقنية تنقيب في المعطيات، تؤمن طريقة جيدة لاستنتاج القواعد. وهي أداة رياضية للتعامل مع غموض وحيرة النظام. غير أن الطريقة أصبحت شعبية فقط بعد أن نشر الباحث كتابه على المجموعات الخشنة (Pawlak, 1991). وهذه الأداة مفيدة جداً في تحليل المعطيات وتوليد القواعد. ومنذ ذلك

الحين، حصل تقدم سريع في هذا المجال. كما أن تطبيق طريقة المجموعات الخشنة لاكتشاف المعرفة، قد أُظهر أيضاً من قبل الباحث Pawlak (1997). حتى الآن يوجد حوالي 1500 مقالة تبحث في نظرية وتطبيقات المجموعات الخشنة. ومن أجل المسح المفصل لهذا المجال يمكن أن يعود القراء إلى Pal & Skworon (1999).

بدأ الباحثون أيضاً باستخدام المجموعات الخشنة في تطوير أنظمة كشف التدخل، حيث يستخدم الباحثون Cai, Guan, Shao, Peng, & Sun (2003) هذه الطريقة لتطوير IDS لكشف الشذوذ. وقام الباحث Zhu et at. (2001) بدراسة مقارنة لأدوات التنقيب في المعطيات مختلفة من أجل IDS، ووجد أن المجموعات الخشنة تبدي أداءً أفضل من الطرق الأخرى.

إن الخصائص التكميلية والاستعمال المتشابه للطريقتين شجع الباحثين لاختيار هجين من تلك الطريقتين. ما زال العمل البحثي في هذا المجال في مراحله الأولى. فقد طور الباحثون Yahia, Mahmod, Sulaiman, & Ahmad (2000) طريقة هجينة من أجل نظام خبير. وحسب معرفتنا، فإن الباحثين Li & Wang (2004) فقط، استخدما طريقة هجينة عصبونية – خشنة من أجل التنقيب في المعطيات.

التعلّم المعتمد على GA

نشرح الآن ونناقش الطريقة المقترحة في العمل المقدم من قبل Bhaskar, Kamath, & Moitra (2004)، ونطور تقنية موثوقة وقوية من أجل IDS. إن الخوارزمية، والمشكلة المرافقة لها، والحلول الممكنة تمثل جميعها موضوع المناقشة. تقترح المقالة آلية تعلّم معتمدة على GA للشبكات العصبونية. وإطار عمل أساسي مُستعار من مجال علم الإدراك. أما الهدف فهو تطوير IDS، الذي يتكّيف للتغيرات في البيئة.

الشبكة العصبونية الصنعية هي طريقة مستخدمة بشكل واسع من أجل التعلّم. بما أن التعلّم باستخدام طريقة الشبكة العصبونية عملية معقدة ومستهلكة للوقت، فإن الاتصال بين التعلّم والتطور، يمكن أن يُستخدم لخفض تعقيد المسألة، وبالتالي تسريع التكّيف. يحاول الباحث Chalmers (1990)، أن يبرهن أن التطور والتعلّم هما العمليتان الأساسيتان الأكثر قابلية للتكّيف. يمكن أن يُنفذ بناء أي نظام تكيفي باستخدام الاتصالية، بالإضافة إلى طريقة وراثية. وفقاً للباحث Charles فإن عملية التعلّم العادية في ANN هي طريقة اتصالية تكون فيها العقد في طبقة ما متصلة مع تلك العقد في طبقة أخرى مختلفة. يختلف نوع النشوء الموجود في الأنظمة المعتمدة وراثياً عن الموجود في الأنظمة الاتصالية. بخلاف الأنظمة الاتصالية التي تدعم الظهور – الظهور التزامني على المستويات، فإن الأنظمة المعتمدة على الوراثة تدعم الظهور – الظهور غير المزامن

مع الزمن. وبالتالي، تُستخدم طريقة لإنجاز ظهور تزامني بواسطة طرق تطويرية، تتضمن تشكيل اتصال غير مباشر بين نمط وراثي ونمط ظاهري. النمط الوراثي هو مجموعة من المعلومات الوراثية المتداولة بين الأجيال (في GA هو عبارة عن سلسلة أو خانات). أما النمط الظاهري فهو تعبير سلوكي للنمط الوراثي، الكيان الذي يتفاعل مع البيئة، وخاضع للاختيار بواسطة ملاءمة تفاضلية. إن الفائدة من استخدام نقل غير مباشر من النمط الوراثي إلى النمط الظاهري، هو أنها تسمح لبحث فضاء غير محدود. سمة البحث الوراثي الحالي هو أن فضاء النمط الوراثي، يكون محدوداً تماماً مقدماً، ولا يستطيع البحث الذهاب خارج هذا الفضاء. لنقل، على سبيل المثال، أننا نحدد نمط وراثي من 5 خانات. فإننا بذلك نقيد فضاء البحث ليتغير من 0 (00000) إلى 32 (11111). وبما أنه من الصعب مقدماً معرفة الحسابات منخفضة المستوى بالضبط، والتي ستكون ملاءمة لسلوك معين عالي المستوى، فمن المعقول استخدام الطرق الوراثية للبحث عن صيغة حسابية ملاءمة منخفضة المستوي.

IDS المعتمد على الطريقة الهجينة

نناقش الآن تفاصيل التجربة المُنفذة لإيجاد نموذج IDS ملائم باستخدام إطار العمل المعطى من قبل الباحث Chalmers. مصدر المعطيات هو اكتشاف المعرفة في قاعدة معطيات (KDD) الكأس (http: //Kdd.ics.uci.edu/databases/kddcup99/kddcup 99.html). تُولّد قاعدة المعطيات هذه عن طريق شبكة الاتصالات المحلية (LAN) للقوى الجوية الأمريكية في مختبرات لينكولن لمعهد ماساشوسيتس التكنولوجي. يشمل أي اتصال على 41 خاصية وخرج نهائي (مشيراً فيما إذا كان الاتصال طبيعياً أو اتصالاً خبيثاً).

تصنف المطيات الأصلية اتصالاً معيناً بأنه طبيعي أو خبيث، وتعطي نوع الهجوم الموافق للاتصال الخبيث. ويكون الخرج ثنائياً حيث يشير إلى الاتصال إلى أنه طبيعي أو خبيث.

كما هو مقترح من قبل الباحثين Williams & Sharda (1994)، ومُصدّق من قبل الباحث Zhu et al. (2001) يتم استخدام مجموعة معطيات متوازية (بمعنى، نسبة متساوية من المعطيات الطبيعية والشاذة). وتُستخدم الطبولوجية غير العادية الأبسط لشبكة أمامية الانتشار وحيدة الطبقة مع 41 عقدة دخل، وعقدة خرج واحدة، وبتعلم مُراقب من أجل التجربة.

يُنفذ التغير في الأوزان في الشبكة العصبونية باستخدام خوارزمية تعلّم معتمدة على GA. من أجل اتصال معطى، من عقدة دخل i إلى عقدة خرج j تتضمن المعلومات المحلية أربعة أمور هي:

- a_i – تفعيل عقدة الدخل i.
- oj – تفعيل عقدة الخرج j.
- tj – إشارة التدريب على عقدة الخرج.
- wij – القيمة الحالية لشدة الاتصال من الدخل i إلى الخرج j.

يجب أن تُرمز المورثة تابع F بحيث:

$$\Delta w_{ij} = F\ (a_{i1}\ o_j,\ t_i,\ w_{ij})$$

يؤخذ F كتابع خطي لأربعة متغيرات تابعة ومنتجات أزواجها الستة، ويعطى بالعلاقة التالية:

$$\Delta w_{ij} = k_0(k_1.w_{ij} + k_2.a_i + k_3.o_j + k_4\ t_j + k_5.w_{ij} + k_6.w_{ij}.o_i + k_7\ w_{ij}.t_i + k_8.a_i.o_j + k_9.a_j.t_i + k_{10}.o_j.t_i)$$

تتألف المورثة من 35 خانة اجمالاً. تُرمزّ الخانات الخمس الأولى بارامتر القياس k_0، الذي يمكن أن يأخذ القيمة 0، ±1/256، ±1/128 ... ±32، ... ±64 عن طريق ترميز أسي. تُرمز الخانة الأولى إشارة ko (0 = سالب ، 1 = موجب)، وتُرمز الخانات الأربعة التالية المقدار. إذا تُرجمت هذه الخانات الأربعة كعدد صحيح j بين 0 و15 فيكون لدينا:

$$/ k_0 / = \begin{cases} 0 & , \quad j = 0 \\ 2^{j-9} & , \quad j = 1,2,...,15 \end{cases}$$

تُرمز الخانات الـــ 30 الأخرى المعاملات العشرة الأخرى في مجموعات من ثلاثة. تعبر الخانة الأولى لكل مجموعة عن الإشارة، وتعبر الخانتان الأخريان عن المقدار 0، 1، 2، أو 4 بواسطة تركيز أسي مماثل. وإذا ترجمنا هاتين الخانتين كعدد صحيح بين 0 و3، عندئذٍ يكون:

$$/ k_l / = \begin{cases} 0 & , \quad j = 0 \\ 2^{j-1} & , \quad j = 1,2,3 \end{cases}$$

تُقسم المعطيات المختارة إلى 30 مجموعة معطيات، تدعى كل مجموعة معطيات مهمة. خارج مجموعات المعطيات لـــ 30، تستخدم 20 مجموعة معطيات للتدريب، وتُمسك 10 مجموعات معطيات للاختبار. تُقيم الصبغيات الممثلة لقيم k. ولتقييم أي صبغي، تُشكل شبكات بحجم ملائم لكلٍّ من المهام العشرين، وينفذ الإجراء من أجل كل مهمة.

- من أجل كل حقبة (دورة) تُقدّم الشبكة بكافة أنماط التدريب، وتُحدّث الأوزان وفقاً لقاعدة التعلّم المُرمزّة. تفوق القيم المطلقة لشدات الاتصال الـــ 20 لمنع هروب قواعد التعلمّ.

- تُقدم الشبكة بكل نمط مرة أخرى، وتُسجل مخرجاته. فإذا كانت المخرجات الفعلية المطلوبة على الجوانب المعاكسة من 0,5، تعتبر عندها الاستجابة كخطأ.
- تُحسب الملاءمة كالآتي: 100 × (1 ــ {عدد الأخطاء}/{عدد الأنماط})، منتجةً قيمة نسبة مئوية بين 0 و100. يُستخدم هذا التابع لبساطته.

تؤخذ ملاءمة أي صبغي على أنها الملاءمة المتوسطة فوق كافة المهمات العشرين، وتُختار الصبغيات بشكل احتمالي لإدراج في التوليد التالي يستند على ملاءمتهم المتراكمة عبر الأجيال. آلية الاختيار هي اختيار روليت بالنتيجة (بمعنى يُدرج الصبغي الأكثر ملاءمة في التوليد التالي). تُختبر ملائمة القاعدة المولدة باستخدام مجموعة الاختبار.

النتائج

يُقدّم هنا تحليل مختصر للنتائج مع الإيضاح. يُستخدم تصالب ثنائي النقطة واختيار نخبوي. وقد حُقّقت أفضل ملاءمة مقدارها 92.4% بمعدل تصالب مقداره 55% ومعدل طفرة 1%.

من أجل التوضيح. تقدم النتيجتان الأفضل المكتسبتان أثناء التجربة. تكون قيمة الملاءمة الأفضل هي 92.4%، والقيم الخاصة للبارامتر K هي 2، 0، 0، 1، 1-، 0، 0، 0، 2-، 2، 0، وتوابع التعلّم الموافقة المُشتقة من هذه المجموعة من القيم هي:

$$\Delta w_{ij} = 2(o_i - t_i\ 2a_j a_i + 2a_j t_i)$$

$$= 2(o_i - t_i)\ (1 - 2a_j)$$

$$= 4\ (a_j - 0.5)\ (t_i - o_i)$$

وتكون قيمة الملاءمة الأفضل التالية هي 90.2% بقيم K: 1-، 0، 0، 1، 1، 0، 0، 0، 2-، 4، 0، على الترتيب. لذلك، فإن قاعدة التعلّم الموافقة هي:

$$\Delta w_{ij} = -1(o_i + t_i - 2a_j\ o_i + 4a_j\ t_i)$$

$$= [2a_j\ (o_i - t_i) - (o_i + t_i)]$$

يُقيم أداء الـــ IDS اعتماداً على الفعالية المتوسطة. والملاءمة المتوسطة على 10 حقبات هي 80.4%. وهذا يعني، بأنه بأي معدل تستطيع IDS أن تكشف أي اتصال خبيث في حوالي 80% من الحالات.

هل هذه التقنية فعّالة؟. إن المجموعات الخشنة المعروفة بأنها أداة تنقيب في المعطيات فعالة من أجل مسائل هذا النوع (zhu et al., 2001). الفعالية وتفاوت التصنيف هما بارامترا الأداء ذي

الاهتمام. لنناقش أولاً المجموعات الخشنة في العموم، وننتقل لتطبيقها على IDS. بعدئذ، تُقدّم المقارنة بين الطريقتين.

المجموعات الخشنة للتنقيب في المعطيات

يعتمد نظرية المجموعات الخشنة على افتراض أنه من كل موضوع محادثة في الكون نربط بعض المعلومات. فإذا كانت دراسة طالب في برنامج ما هي موضوعاً، تكون المواد المأخوذة والعلاقات في المواد هي المعلومات المتعلقة بالموضوع. تكون المواضيع المميزة بنفس المعلومات متعذرة التمييز (متماثلة) فيما يتعلق بالمعلومات المتوفرة حول تلك المواضيع. إن علاقة عدم قابلية التمييز المُولدة بهذا الأسلوب هي الأساس الرياضي لنظرية المجموعات الخشنة.

أي مجموعة من كافة المواضيع المُتعذر تمييزها تدعى مجموعة أولية، وتشكل وحدة أساس المعرفة المسماة "ذرة". أي اتحاد لمجموعة أولية ما يدعى مجموعة متموجة، وإلا فهي مجموعة خشنة. لذا، نستطيع القول بأن كل مجموعة خشنة تمتلك حداً غامضاً. بخلاف المجموعات المتموجة، هناك مواضيع في الكون لا يمكن أن تصنّف بثقة لتكون عنصراً ما من المجموعة الخشنة أو من متمماتها. لذا، فهناك عناصر يمكن أو لا يمكن أن تكون عنصراً من المجموعة، لندرس مثالاً على هذا المفهوم. افرض أننا نريد إيجاد ما إذا شخص ما يستطيع أن يكون رياضياً جيداً، أو لا اعتماداً على العمر واللياقة من (الجدول 2).

الجدول (2) مجموعة معطيات للتصنيف الخشن.

	العمر	اللياقة	رياضي
1x	16-30	50	نعم
2x	16-30	0	لا
3x	31-45	25	لا
4x	31-45	25	نعم
5x	46-60	49	لا
6x	16-30	49	نعم
7x	46-60	49	لا

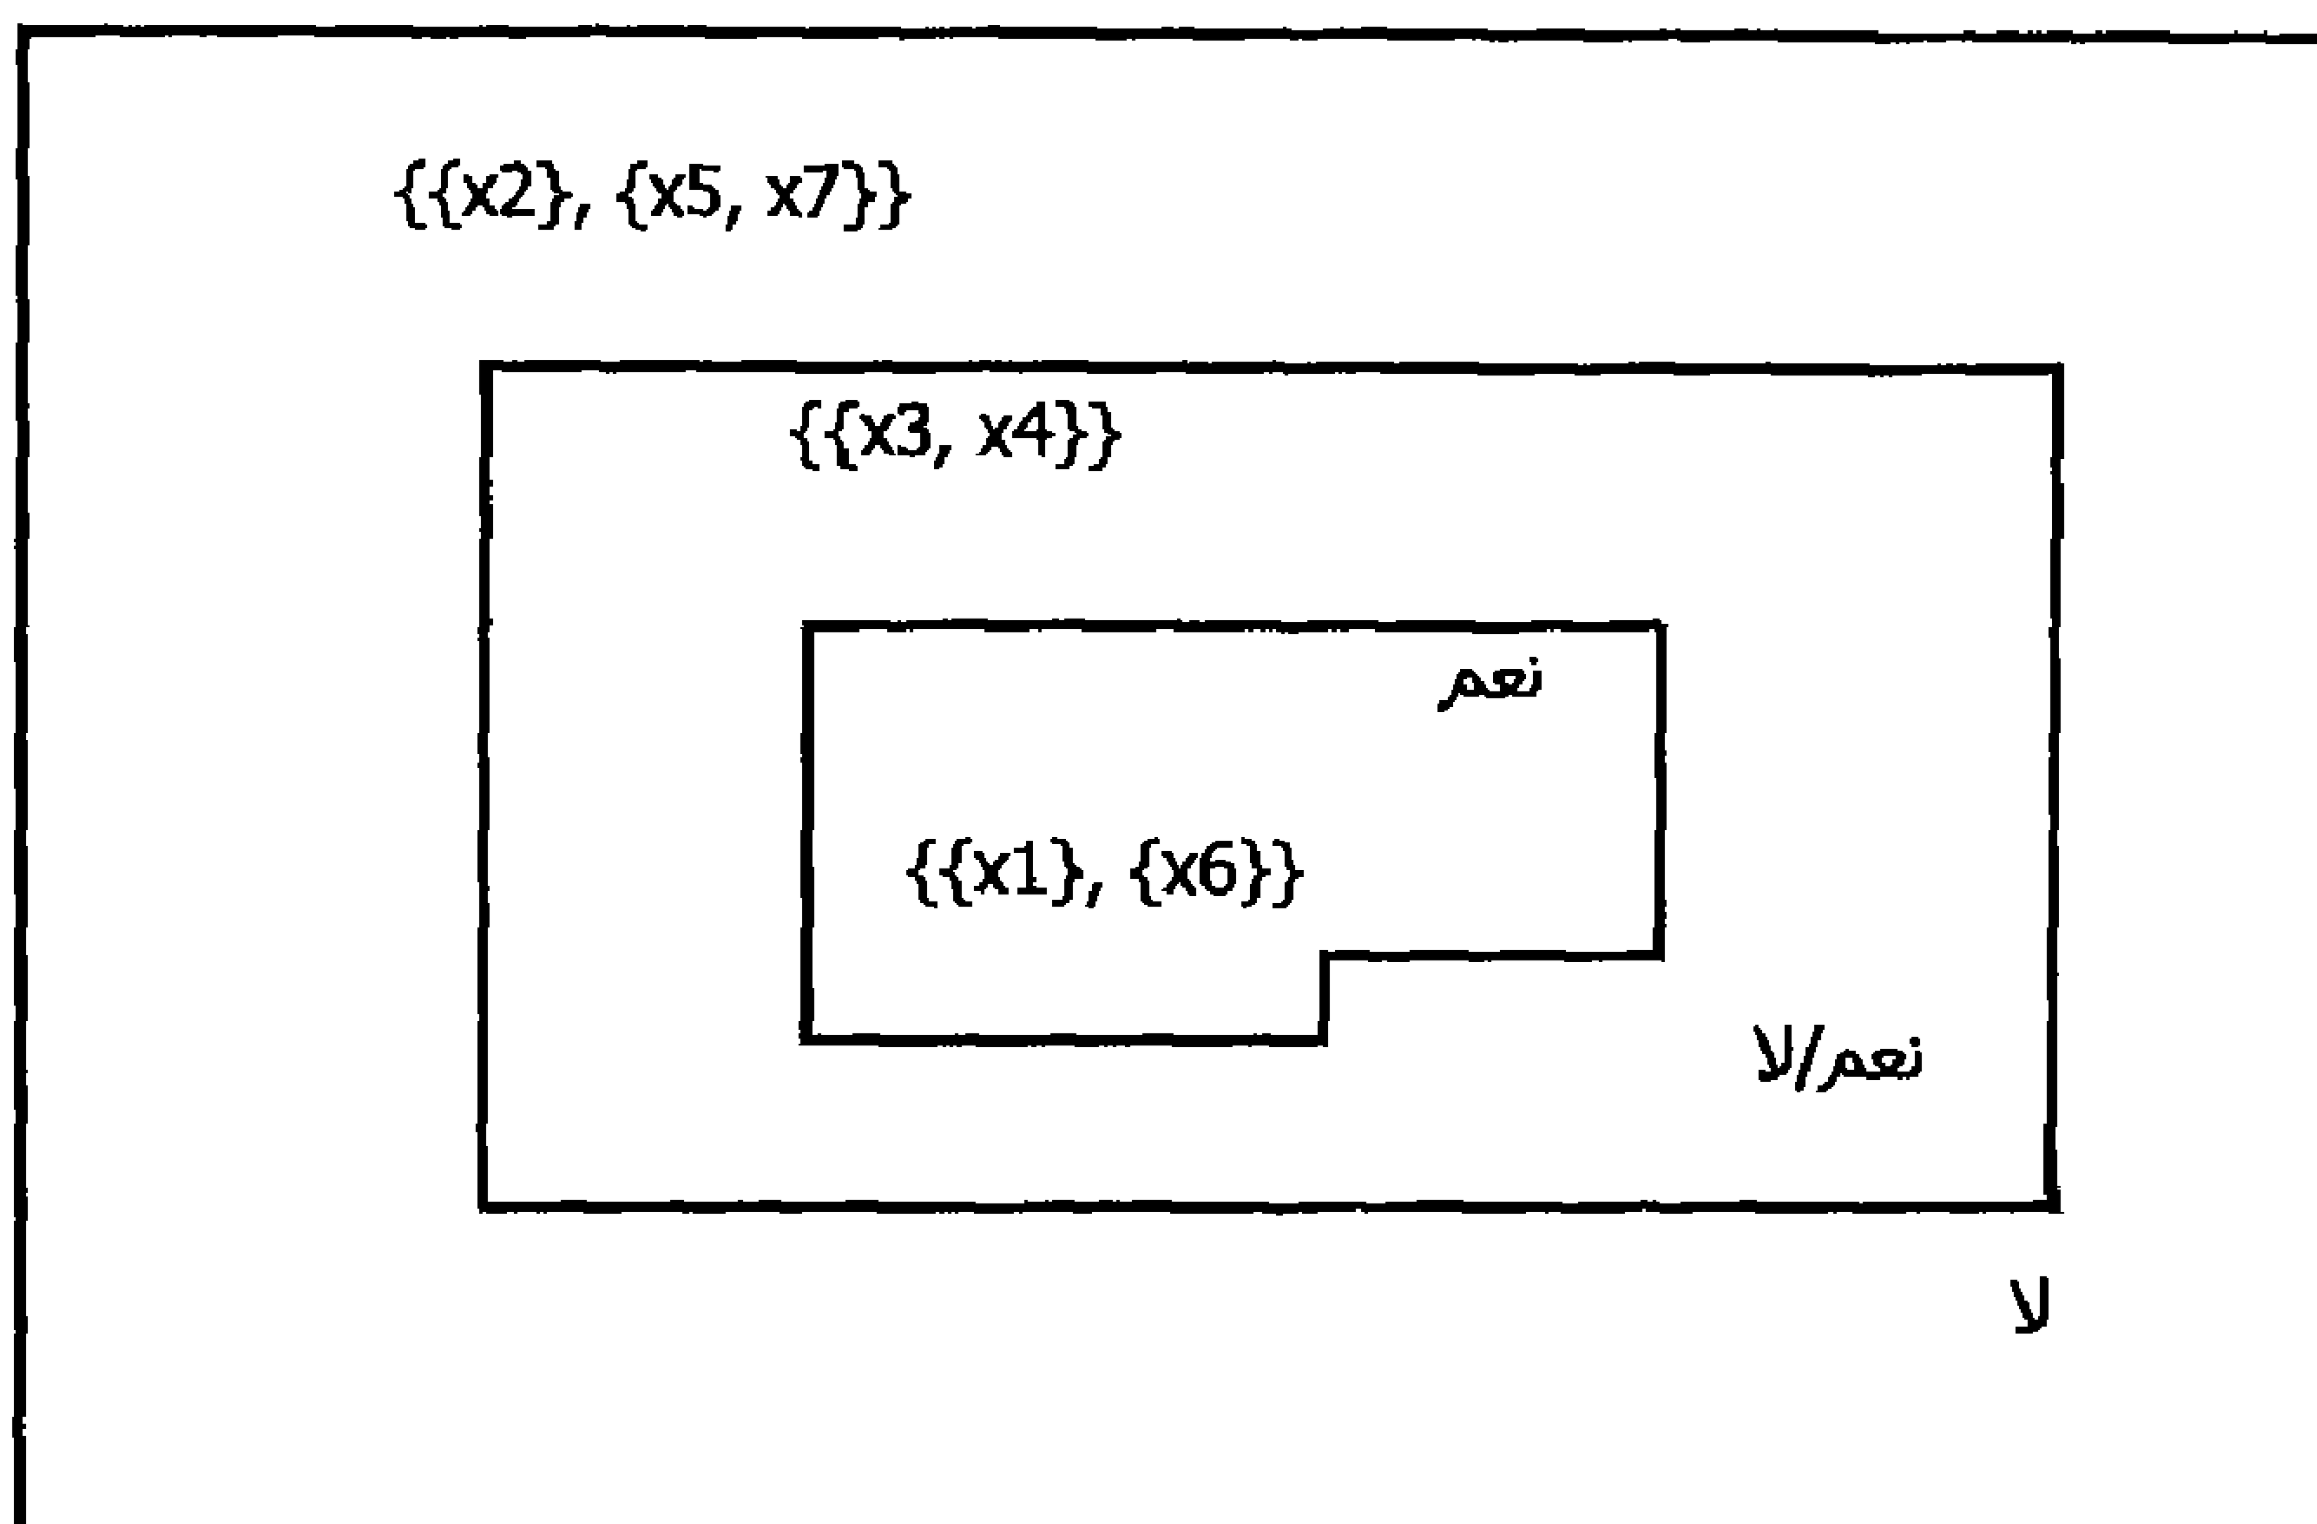
من الممكن أن نلاحظ بسهولة، بأن الأزواج X_3، X_4 وX_5، X_7 لها نفس المجموعة من قيم الدخل، ولكن يمتلك الزوج الأول مخرجات مختلفة، في حين يمتلك الزوج الثاني نفس الخرج. لذا، فإنه من الصعب إيجاد قاعدة ما للخرج اعتماداً على المدخلات. نحاول إيجاد علاقات عدم قابلية التمييز من أجل خرج محدد ما اعتماداً على المدخلات.

IND ({العمر, اللياقة}) = ({x_1}, {x_2}, {x_3, x_4}, {x_5, x_7}, {x_6})

لذلك، نحاول من الجدول تصنيف هذه المجموعات الجزئية إلى مجال معين ما (نعم/لا). يمكن أن تصنّف كافة المجموعات الجزئية، باستثناء $\{x_3, x_4\}$ إلى أحد المجالات. ولكن $\{x_3, x_4\}$ من الصعب تصنيفه. لذلك، إذا كان العمر في المجال من 31 إلى 45، ومستوي اللياقة مساوياً لـ 25، فقد يكون، أو قد لا يكون الشخص رياضياً جيداً. يأتي هذا العنصر في المنطقة الخشنة من المجموعة. المجالات والعناصر المنتمية لذلك المجال مبينة على (الشكل 1). إن وجود المجال نعم/لا مع أصلية لا صفرية، يظهر أن هذه المجموعة هي مجموعة خشنة، والعناصر في هذه المنطقة الخشنة هي $\{x_3, x_4\}$. تزودنا نظرية المجموعات الخشنة بطرق لمعالجة الغموض الموجود في المجموعة.

تمت مناقشة استخدام المجموعات الخشنة من أجل التنقيب في المعطيات في قسم مسح المادة المنشورة. وهنا نشرح الخطوات الأساسية والمصطلحات المستخدمة في تحليل معطيات المجموعات الخشنة.

الشكل (1) *تمثيل تخطيطي للمجموعات الخشنة*



جدول المعطيات

تُعطى المعطيات عموماً على شكل جدول، نتوقع منه استخلاص بعض القواعد شكلياً. أي جدول معطيات هو عبارة عن أربعة أعمدة $S = <u, Q, V, f>$، حيث أن u – هي مجموعة محدودة من المواضيع (الكون)، $Q = \{q_1, q_2, ..., q_m\}$ – وهي مجموعة محدودة من المساهمات، V – هو مجال المساهمة q، و $f: U \times Q \rightarrow V$ – يدعى بتابع المعلومات، بحيث أن $f(x,q) \in V_q$. كل مجموعة جزئية (غير خالية)من المساهمات P تُرافق بعلاقة عدم قابلية التمييز على UK يرمز لها بالرمز I_P.

$I_P = \{(x, y) \in U \times U: f(y, q)\} \qquad \forall q \in P$

إذا كان $K(x, y) \ni I_P$ فيُقال عندها بأن الموضوعان x و y غير قابلين للتمييز – P.

تقريب

لتكن S جدول معطيات ما، وX مجموعة جزئية غير خالية من U، و$\phi \neq P \leq Q$. يُعرّف التقريب الأدنى – P والتقريب الأعلى P لـــ X في S على الترتيب كالتالي:

$$\underline{P(x)} = \{x \in U : I_P(x) \subseteq X\}$$
$$\overline{P(x)} = U_{x \in X}\ I_P(x)$$

وهكذا، فإن العناصر $\underline{P(x)}$ هي الجميع وفقط تلك المواضيع التي تنتمي بالتأكيد إلى المجموعة. و $\overline{P(x)}$ هي كافة تلك العناصر، التي تنتمي إلى المجموعة. في المجموعة المبينة في (الشكل 1)، $\{x_1, x_6\}$ هي عناصر $\underline{P(x)}$، و$\{x_1, x_3, x_4, x_6\}$ هي عناصر $\overline{P(x)}$.

التبعية والمُختَفضات

تعتمد أي مجموعة من الخواص $T \subset Q$ كلياً على مجموعة ما من الخواص $P \subset Q$، إذا كانت كافة قيم الخواص من T محددة بشكل وحيد بقيم خواص من P، أي إذا وجدت تبعية تابعية ما بين تقييم خواص من P ومن قبل الخواص من T.

إن المعطيات الزائدة عن الحاجة هي قضية مهمة جداً للاهتمام في استخلاص القواعد. ليكن PCQ و$p \ni P$. يقال عن الخاصية أنها زائدة في P، إذا كان $I_P = I_{P-\{p\}}$، وإلا فإن p هي أساسية في P.

تكون المجموعة P مستقلة، إذا كانت كافة خواصها أساسية. وتكون المجموعة الجزئية 'P من P مُختَفضة من P (يرمز لها بالرمز (Red(P))، إذا كانت 'P مستقلة و$I_{P'} = I_P$. وإذا كان لدينا أكثر من مُختَفض واحد، عندئذ يدعى تقاطع المجموعات لكافة المُختَفضات بنواة مجموعة المعطيات.

قواعد القرار

يمكن أن تُقسم خواص القرار إلى خواص الشرط وخواص القرار. وتدعى العلاقة بين خواص الشرط وخواص القرار باستخلاص القاعدة. وهذه القواعد هي عبارات منطقية (معاني ضمنية) من النوع (.... if.... then)، حيث يحدد السابق القيم المفروضة بخاصية واحدة أو بعدة خواص شرط، ويستلزم اللاحق تعيين صف واحد أو عدة صفوف قرار. وهكذا، تكون صيغة القاعدة كالتالي:

$$\text{if } f(x,q_1)==r_{q_1} \,\&\, f(x,q_2)==r_{q_2} \,\&\ldots f(x,q_n)==r_{q_n}$$
$$\text{then } X \in Y_{j1} \text{ or } Y_{j2} \text{ or} \ldots Y_{jk}$$

يدعم أي موضوع x و U قاعدة القرار r، إذا تطابق وصفه مع كلٍّ من القسم الشرطي وقسم القرار للقاعدة. كما أننا نقول أيضاً بأن قاعدة القرار r تغطي الموضوع x، إذا طابقت على الأقل القسم الشرطي للقاعدة. يُميّز كل قرار بقوته المُعرّفة كعدد المواضيع الداعمة للقاعدة.

طريقة المجموعات الخشنة من أجل IDS

ينصب اهتمامنا على المجيء بشبكة عصبونية جيدة لكشف التدخل. ولقد أظهرت الشبكة العصبونية المعتمدة على GA نتائج واعدة. إن المجموعة الخشنة هي طريقة مثبتة جيداً. من أجل التنقيب في المعطيات، ولذلك قمنا بمقارنة هاتين الطريقتين، أولاً، قيمنا مجموعة المعطيات مع المجموعات الخشنة، ويُقدّم تحليل موجز لهذه الطريقة في هذا القسم.

المعطيات والمعالجة الأولية

تشمل مجموعة المعطيات على 41 خاصية دخل وخرج ثنائي واحد. تُجرى المعالجة الأولية في أسلوب مماثل لما شرح سابقاً تحت النموذج الهجين من أجل IDS. لذلك، فإن مجموعة المعطيات المستخدمة في هذه التجربة هي نفسها التي استخدمت في نموذج ANN.

إيجاد المُختفضات

المُختَفض هو مجموعة من أكثر الخواص المفيدة وذات المعنى في مجموعة المعطيات. وقد استخدمنا مفهوم "مصفوفة عدم قابلية التمييز" لإيجاد المُختَفض. ويعتمد تطبيقه على بنية تدعى مصفوفة عدم قابلية التمييز. فهو يأخذ الاختلاف في مجموعة المعطيات من أجل خرج معين لإيجاد المُختَفض.

باستخدام الطريقة على مجموعة معطياتنا، حصلنا على 12 مُختَفض بثلاثة خواص لكل واحد. لذا، نحتاج للتركيز على هذه المُختَفضات فقط من أجل تجربة المجموعات الخشنة.

تخفيض القاعدة

بعد إيجاد المُختَفض، نحن بحاجة لإيجاد القواعد، التي بموجبها سيُنفذ التصنيف. من أجل تخفيض القاعدة، استخدمنا تغطية صغرى أساسية. ويُستخدم ذلك خوارزمية التغطية الصغرى الأساسية

(عدد أصغري من قواعد الاختبارات القصيرة الممكنة، التي تغطي كافة الأمثلة). وتمت صياغة تسع قواعد. تمتلك القاعدة الأفضل قوة مقدارها 79، ودعماً مقداره 79 خارج 150 نقطة معطيات.

إثبات الصلاحية

إن أي قاعدة مُصاغة بطريقة ما معينة من الضروري أن تُصدّق. كما تُستخدم أيضاً التغطية الصغرى الأساسية من أجل إثبات الصلاحية. جُدولت النتائج في (الجدول 3). يمثل الخرج الثنائي 0 اتصالاً عادياً، بينما يمثل الخرج 1 اتصالاً خبيثاً.

يظهر (الجدول 3)، بأن الكفاءة الكلية للنموذج هي 80%، وتم كشف اتصال خبيث في 83% من الحالات، ولكن كان الانحراف كبيراً جداً (30%). تظهر مقارنة النتائج المكتسبة بالشبكة العصبونية والمجموعات الخشنة، بأنه لدى تلك الطرق تفاوت كبير، يشكل خطراً كامناً على النظام. لذلك، هناك حاجة لطريقة ما تُخفض تفاوت التنبؤ. نستعمل مؤازرة تفعيلية للطريقتين، ونقترح استخدام الطريقة التكاملية المسماة "بالطريقة العصبونية – الخشنة" من أجل تحسين دقة النظام.

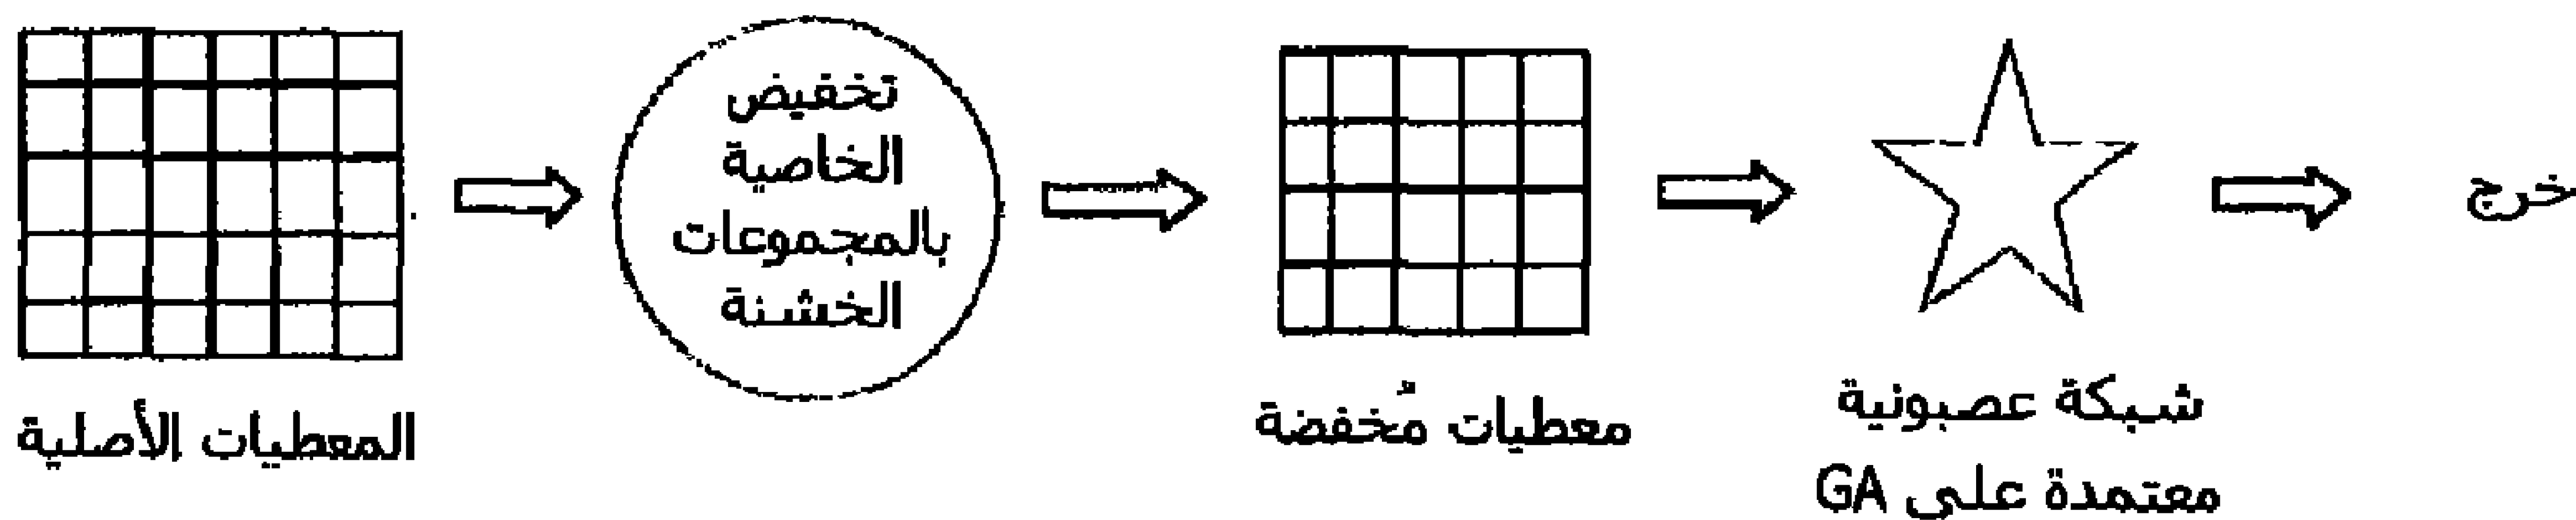
الجدول (3) كفاءة IDS المعتمدة على المجموعات الخشنة

	صحيح	غير صحيح	غير معروف
الكلي	80.00±11.16	18.67±10.24	1.33±02.67
0	78.18±12.08	21.11±11.87	0.71±02.14
1	83.33±30.73	13.33±30.55	3.33±10.00

الطريقة العصبونية - الخشنة من أجل IDS

نقترح في هذا القسم نموذجاً تكاملياً من أجل IDS يُسمى "بالنموذج العصبوني – الخشن"، ويكون التركيز على الاحتفاظ بالمتوسط وتخفيض تفاوت التنبؤ انظر (الشكل 2).

الشكل (2) *طريقة هجينة "عصبونية - خشنة" من أجل تصنيف الخرج.*



تُستخدم مجموعة المعطيات المُخفضة من أجل التحليل بنموذج الشبكة العصبونية المقترحة ينفذ تخفيض مجموعة المعطيات باستخدام مجموعة خشنة. لذلك، تكون الخطوات المتضمنة في هذه الطريقة الهجينة هي:

- تخفيض مجموعة المعطيات باستخدام نظرية المجموعة الخشنة. إيجاد كافة المُختَفضات لمجموعة المعطيات والحصول على اتحاد كافة مجموعات المُختَفضات. نأخذ خواص هذه المجموعة كخواص مجموعة المعطيات المُخفضة.
- استخدام نموذج الشبكة العصبونية على مجموعة المعطيات المخفضة لتطوير IDS.

تظهر النتائج بأن الفعالية (الكفاءة) الأفضل للنموذج الهجين هي 86%، بينما الفعالية المتوسطة هي 79.4%. يوجد انخفاض طفيف في فعالية الحالة الأفضل بسبب فقدان بعض المعلومات، بما أننا نستخدم المُختَفضات للحصول على مجموعة مخفضة من المعطيات. لا يوجد أي اختلاف احصائي في الفعالية المتوسطة عند مقارنها بالطرق الأخرى. النقطة اللافتة للنظر هي الانخفاض في الانحراف المعياري إلى 31.5%. وكان هذا بسبب إزالة المعلومات غير المرغوبة بإغناء مجموعة التدريب باستخدام المُختَفضات.

النتائج والمناقشة

نقارن في هذا القسم النتائج المكتسبة بالطرق الثلاث طريقة الشبكة العصبونية المعتمدة على GA، وطريقة المجموعات الخشنة، والطريقة العصبونية الخشنة. ويتضمن ذلك تحليل وتفسير النتائج.

بارامترات الأداء الهامة لـ IDS هي الفعالية وانحرافها المعياري. إذا كان النظام ذا مهمة حاسمة وخطيرة، عندئذ تُعتبر أيضاً فعالية الحالة الأسوأ لأي IDS بارامتراً هاماً. جُدوّلت النتائج لكل طريقة في (الجدول 4).

أعطينا عدداً لكل طريقة من أجل راحتنا للتمثيل السهل. والأرقام المعطية هي:

1. طريقة المجموعات الخشنة.
2. طريقة الشبكة العصبونية.
3. الطريقة العصبونية – الخشنة.

نقارن الآن فعالية الطرق اعتماداً على حالتها الأفضل، وحالتها الأسوأ، وحالة المتوسط. وكما تم شرحه، نأخذ الانحراف المعياري كبارامتر مقارنة.

الجدول (4) مقارنة الفعالية

الطريقة	الأفضل	المتوسط	الأسوأ	الانحراف المعياري
1	94.00	80.00	62.00	11.160
2	92.00	80.40	64.00	08.356
3	86.00	79.60	74.00	3.627

يمكننا ملاحظة أن الشبكة العصبونية المعتمدة على GA تمتلك الفعالية المتوسطة الأعلى، ولكن في نفس الوقت هي تأتي بتأثير غير مرغوب من التفاوت العالي في التنبؤ وتكون المجموعة الخشنة طريقة أفضل، إذا اعتبرنا فقط فعالية الحالة الأفضل. وسيعتمد أشخاص أمن الأنظمة الشبكية الطريقة العصبونية – الخشنة بسبب الاختلاف المنخفض وإدارة فعالية حالة متوسطة جيدة.

يعطي (الجدول 5) خطأً في التصنيف، يدعى عموماً كخطأ من النوع I (يُفسر الاتصال الطبيعي كاتصال خبيث)، والخطأ من النوع II (يُفسر الاتصال الخبيث كاتصال طبيعي). ومن الواضح جداً، بأن الخطأ من النوع II أكثر ضرراً من الخطأ من النوع I من أجل أي نظام مأمون.

الجدول (5) مقارنة الأخطاء

الطريقة	الخطأ من النوع I		الخطأ من النوع II	
	المتوسط	الانحراف المعياري	المتوسط	الانحراف المعياري
1	21.11	11.87	13.33	30.55
2	22.45	10.85	12.35	18.50
3	20.45	8.54	10.58	12.50

يجب أن يكون لدينا خطأ من النوع II صغير جداً، باعتبار أن كلفة تسوية النظام المناسبة أكبر بكثير من كلفة النظام، وهذا لا يكون متاحاً لأي مستخدم عادي. ومن جديد، تكون الطريقة العصبونية – الخشنة ذات أداء أفضل، إذا اخترنا هذا المعيار. كما أن الانحراف المعياري لهذه الطريقة هو الأخفض. مقارنة الفعالية المتوسطة للطرق المختلفة المقدمة في (الجدول 6).

الجدول (6) مقارنة فعالية الاختبار z.

الطرق	z (حسابي)	z (جدولي)	الحكم
2 & 1	0.366	1.96 (a = 0.05)	تشير مقارنة المتوسطات بعدم وجود اختلاف ذو أهمية
3 & 1	0.280		
3 & 2	0.723		

ولكن، الذي يحدد فعلاً كشف التدخل هو التغيير، الذي يجب أن تقدمه كل طريقة. لذلك، نحلل الانحرافات المُسبّبة من قبل طريقة. وهذا ما هو مقدم في (الجدول 7).

الجدول (7) مقارنة الانحرافات المعيارية - اختبار F

الطرق	F (حسابي)	F (جدولي)	الحكم
2 & 1	1.782	1.861 (df = 58) (a = 0.01)	تثبت مقارنة التغيير وجود اختلاف هام في مصلحة الطريقة العصبونية- الخشنة
3 & 1	9.610		
3 & 2	5.393		

استخدمنا الطرق الأفضل المتوفرة لكشف التدخل، ولا نستطيع إحصائياً القول بأنه يوجد اختلاف في الفعالية المتوسطة لأيٍّ من تلك الطرق الثلاث. إن تغيير الطريقة العصبونية – الخشنة أقل بشكل ملحوظ من تغيير الطريقتين الأخريين في مستوي ثقة مقداره 99%. تفوق الطريقة العصبونية الصنعية أداءً الطرق الأخرى فيما يتعلق بفعالية الحالة الأسوأ، والانحراف المعياري. وبالتالي، يجب أن تكون هي المُختارة في أنظمة كشف التدخل.

الاستنتاج والبحث المستقبلي

لقد ناقشنا في هذا الفصل طريقة التنقيب في المعطيات من أجل IDS. وقد أعطينا مقدمة مختصرة مع مراجع مناسبة لكلٍّ من المجالات المذكورة لمساعدة القراء لتحسين مفاهيمهم. وهذا الأمر من المستحيل أن يكون كاملاً، ويتوجب على القراء العودة إلى الكتب في كل مجال معين لمعرفة تعقيدات هذه الطرق.

يمكن أن تظهر الشبكة العصبونية أداءً أفضل باختيار بنية هندسية وخوارزمية تعلّم مناسبتين. ينصب تركيز هذه المقالة على المجيء بخوارزمية تعلّم لا تدريجية، بحيث تُحسن فرص التغلب على النهايات الصغرى المحلية. إن أي شبكة عصبونية أمامية الانتشار وحيدة الطبقة بتعلّم مُراقب معتمد على GA تعطي نتائج واعدة. تظهر المقارنة مع المجموعات الخشنة نتائج مماثلة. لقد بيّنا باستعمال المميزات التكميلية، كيف يمكن لطريقة تكاملية أن تخفض الخواص، وتُولّد حلاً أفضلاً.

إن تقنيات التنقيب في المعطيات هي تقنيات معتمدة على المعطيات. ويلزم مجموعة جيدة من معطيات التدريب لاتخاذ قرارات فعّالة. استخدمنا معطيات كأس KDD، وقارنا الطرق المقترحة. من المفيد فحص تغيير هذه التقنيات عبر مجموعة متغيرة من المعطيات. وسيكون تطبيق الطرق المقترحة مع التعديلات اللازمة في مجالات أخرى امتداداً جيداً لهذا العمل. كما يمكن لشخص أن يأتي بخوارزميات فعّالة، تخفف عبء تدريب الشبكة العصبونية. إن بناء IDS متين بتقييم الطريقة من أجل شروط مستوي ضجيج مختلفة هو قضية مهمة للدراسة المستقبلية.

المراجع

Balajinath, B.,& Raghavan,S.V. (2001). Intrusion detection through learning behavior model. Computer Communications, 24 (12), 1202-1212.

Bhaskar, T., Kamath, N., & Moitra, S.D. (2004). A hybrid model for network security systems: Integrating intrusion detection system with survivability. Working Paper Series 507/2004. Indian Institute of Management Calcutta.

Bonifacio, J.M., Cansian, A.M., & Carvalho, A.C. (1997). Neural networks applied to intrusion detection systems. In Proceedings of the International Conference on Computational Intelligence and Multimedia Application (pp. 276-280).

Cai, Z., Guan, X., Shao, P., Peng, O., & Sun, G. (2003). A rough set theory based method for anomaly intrusion detection in computer network systems. Expert Systems, 20(5), 251-259.

Chalmers, D. (1990). The evolution of learning: An experiment in genetic connectionism. In Proceedings of 1990 Connectionist Model Summer School. Morgan Kaufmann.

Chebrolu S..Abraham, A., & Thomas, J.P. (2004). Feature deduction and ensemble design of intrusion detection system. Computers and Security (forthcoming).

Crosbie, M., & Spafford, G. (1995). Applying genetic programming to intrusion detection. In Proceedings of AAAI 1995 Fall Symposium.

Denning, D.E. (1987). An intrusion detection model. IEEE Transactions on Software Engineering, 13(2), 222-232.

Garfinkel S., & Spafford, E. (1991). Practical UNIX security. O'Reilly and Associates Inc.

Goldberg, D.E. (1989). Genetic algorithms in search, optimization and machine learning. Addison-Wesley.

Hassoun,M.H.(I 998). Fundamentals of artificial neural networks. India: Prentice Hall of India.

Heady R., Luger, G., Maccabe, A., & Servilla, M. (1990). The architecture of network-level intrusion detection system, technical report, CS90-20. University of Mexico.

Holland, J.H. (1975). Adaptation in natural and artificial systems. Ann Arbor: University of Michigan Press.

Joo, D., Hong, T., & Han, I. (2003). The neural network models for IDS based on the asymmetric costs of false negative errors and false positive errors. Expert Systems with Applications, 25 (1), 69-75.

Koza, J.R. (1992). Genetic programming: On programming of computers by means of natural selection. Cambridge, MA: The MIT Press.

Lee, W., Stolfo, S.J., & Mok, K. (1999). A datamining framework for building intrusion detection model. In IEEE Symposium on Security and Privacy, 120-132.

Li, R., & Wang, Z. (2004). Mining classification rules using rough sets and neural networks. European Journal of Operational Research. 157, 439-448.

Lippmann, R., & Cunningham, R.K. (2000). Improving intrusion detection performance using keyword selection and neural networks. Computer Networks, 34, 597-603.

Lunt, T.F. (1993). A survey of intrusion detection techniques. Computer and Security, 12(4), 405-418.

Mukherjee, B., Heberline, L.T., & Levitt, K.N. (1994). Network intrusion detection. IEEE Network. 8(3), 26-41.

Pal, S.K., & Skworon, A. (Eds.) (1999). Rough fuzzy hybridization: A new trend in decision making. Springer.

Pawlak, Z. (1982). Rough sets. International Journal of Computers and Informations Sciences, 11.341-356.

Pawlak, Z. (1991). Rough sets: Theoretical aspects and reasoning about data. Kluwer Academic Publisher.

Pawlak, Z. (1997). Rough set approach to knowledge based decision support. European Journal of Operational Research, 99, 48-57.

Russel, D., & Gangeni, Sr., G.(1991). Computer security basics. O'Reilly and Associates.

Williams, R.L., & Sharda, R. (1994). Bankruptcy prediction using neural networks. Decision Support Systems, 11, 545-557.

Yahia, M., Mahmod, R., Sulaiman, N., & Ahmad, F. (2000). Rough neural expert systems. Expert Systems with Applications, 18(2), 87-99.

Zhang, C., Jiang, J., & Mohamed, K. (2004). Intrusion detection using hierarchical neural networks. Pattern Recognition Letters (forthcoming).

Zhu, D., Premkumar, G., Zhang, X., & Chu, C.-H. (2001). Data mining for intrusion detection: A comparison of alternative methods. Decision Sciences, 32(4), 635-660.

الفصل السادس عشر

تقنيات الذكاء الصنعي التعاونية لتصنيف الأطياف النجمية: استراتيجية هجينة

ملخص

يصف هذا الفصل طريقة هجينة للتصنيف غير الموجود لأطياف النجوم الضوئية المنخفضة التمييز. يشكل تصنيف النجوم في النظام MK القياسي مسألة هامة في مجال الفيزياء الفلكية، بما أنه يساعد في تنفيذ دراسات تطور نجمية لائقة خاصة. لقد استخدمت الطرق اليدوية المعتمدة على الدراسة البصرية للأطياف النجمية كثيراً وبنجاح من قبل الباحثين لسنوات عديدة، ولكنها لم تعد فعّالة بسبب التقدم المدهش لتقنيات جمع الأغراض، التي تجمّع كمية ضخمة من المعطيات الطيفية خلال زمن قصير نسبياً.

وبالتالي، نقترح نظاماً تعاونياً قادراً على تصنيف النجوم آلياً وبفعالية بتطبيق على طريقة كل طيف أو طرق مشتركة أكثر ملاءمة، تضمن تصنيفاً موثوقاً، منسجماً ومتكّيفاً. ويكمن هدفنا الأخير في دمج عدة تقنيات ذكاء صنعي في نظام هجين فريد.

مقدمة

هذا الفصل هو جزء من مشروع عاملي مكّرس لدراسة الأطوار الأخيرة للتطور النجمي. والدراسة التطورية هي جزء أساسي من الفيزياء الغالبية، لأنها تسمح لنا باكتشاف واتباع التغيرات الزمنية للظروف الفيزيائية والكيميائية للنجوم. ويكون الهدف العام لمشروعنا هو تطوير نظام آلي من أجل تحديد البارامترات النجمية الفيزيائية والكيميائية (النوع الطيفي، السطوعية، درجة الحرارة، المعدنية (الفلزية)...الخ) من خلال الدراسات الطيفية (أو المطيافية) البصرية وتقنيات الذكاء الصنعي.

إن المطيافية هي من أقوى التقنيات المتوفرة حالياً لدراسة النجوم، وبشكل خاص، لدراسة ظروفها الفيزيائية (درجة الحرارة، الضغط، الكثافة... الخ)، والمكونات الكيميائية (H، He، Ca، K....الخ). في الشروط العامة، يتألف أي طيف نجمي من توزيع ضوء مستمر لجسم أسود مشوّه بالامتصاص الحاصل ما بين النجوم وإعادة إصدار الضوء، وبوجود خطوط الامتصاص، وخطوط الإصدار، والروابط الجزئية (Zombeck, 1990).

تُجمع الأطياف النجمية من المناظير التلسكوبية براسمات طيف وكواشف. يجمع الرّصاد التوزيع التدفقي لكل جسم، ويخفضوا تلك المعطيات للحصول على طيف أحادي البعد مُعاير في التدفق الطاقي (erg^{-1} cms^{-2} s^{-10} A^{-1}) والطول الموجي (Å).

وكجزء من المشروع العام، قمنا بجمع عينة كبيرة من الأطياف النجمية البصرية من المشاهدات الفلكية المُنفذة بعدة مناظير تلسكوبية. عندما تُجمّع وتُخفّض الأطياف من عينة متجانسة من النجوم، يمكن أن تساعد دراسة توزيع الأنواع الطيفية وتحليل المعطيات الطيفية على فهم التغيير الزمني للظروف الفيزيائية للنجوم من وجهة نظر إحصائية، وبالتالي للتعلّم حول تطوّرها. وهذا هو السبب في كون التصنيف الطيفي واحد من السمات الأساسية للدراسة التطورية للنجوم، ويجب أن يُنفذ الطور بأسلوب سريع، فعال، ودقيق.

بغية استخلاص معلومات مفيدة عن الأطياف الفردية ودراسة التطور النجمي في العينة الكاملة، يتوجب علينا إكمال تصنيف طيفي صلب ومنظم في أطيافنا المُجمّعة في النظام الحالي للباحثين Morgan-Keenan (MK).

اُقترح نظام التصنيف MK لأول مرة في عام 1943 من قبل الباحثين Morgan وKeenan، وواجه العديد من التنقيحات منذ ذلك الحين (Morgan, 1943). وهذا النظام ثنائي الأبعاد هو الوحيد المُستخدم على نطاق واسع للتصنيف النجمي.

وإحدى ميزاته الرئيسة هي أن تصنيفات MK غالباً ما تكون استاتية، لأنها تعتمد على الدراسة البصرية للأطياف، وعلى مجموعة من المعايير القياسية. على أية حال، يمكن أن تصنف نفس الأطياف بشكل متباين من قبل خبراء مختلفين، وحتى بشكل مختلف من قبل نفس الشخص في أوقات مختلفة. يُحدد نظام التصنيف هذا مقدار درجات الحرارة النجمية، ومستويات السطوع. تُقسم النجوم إلى مجموعات (أنواع طيفية)، تعتمد - بشكل رئيسي على شدة خطوط امتصاص الهيدروجين، وعلى وجود أو غياب بعض الخطوط الهامة (Fe, He, Ca)، والروابط الجزيئية. تُقسم درجة حرارة النجوم في سلسلة تدعى OBAFGKM ممتدة من النجوم الأسخن (النوع O) إلى الأبرد (النوع M). تُقسم هذه الأنواع الطيفية أيضاً إلى أجزاء أصغر بالنظام العشري الممتد من 0 (الأسخن) إلى 9.5 (الأبرد). بالإضافة إلى ذلك، يُعين صف السطوعية من (I إلى V)، إلى

النجم الذي يعتمد على النصوعية النجمية الداخلية، بمعنى أن النجم الأسخن للنظام MK سيكون من النوع O0، والأبرد سيكون النجم M9.

يوضح (الجدول 1) الخصائص الرئيسية لكل نوع طيفي في نظام التصنيف القياسي MK. يجب أن يملك أي نظام تصنيف حلاً وسطاً بين الإبقاء على المعلومات الكاملة للأطياف، والحاجة لخلاصة موجزة من هذه المعلومات. يتم الحصول على خلاصة مثالية بشكل واضح عن طريق دراسة النوع الطيفي والسطوعية في النظام MK.

الجدول (1) السمات الطيفية الرئيسة في النظام MK.

النوع	اللون	الخطوط البارزة
O	الأكثر زرقة	He المؤيّن
B	مزرّق	He متعادل، H متعادل
A	أزرق - أبيض	H متعادل
F	أبيض	H متعادل، Ca مؤيّن
G	أصفر - أبيض	H متعادل، Ca مؤين الأشد
K	برتقالي	معادن متعادلة (Ca، Fe)، Ca مؤين
M	أحمر	جزئيات ومعادن متعادلة

يُنفذ تقدير النوع الطيفي وسطوعية النجوم غالباً من قبل خبراء بشر، يقومون بتحليل الأطياف يدوياً بمساعدة خبرتهم الخاصة. تؤدي هذه التحليلات اليدوية عادةً إلى تصنيف MK للأطياف. تعتمد تقنيات التصنيف اليدوية غالباً على الدراسة البصرية للأطياف، وعلى مجموعة من المعايير القياسية (Zombeck , 1990).

يختار المُصنفون البشر بيان مصور (كتالوج) مرجعي للأطياف المُصنفّة مسبقاً، تُستخدم كدليل موثوق في العملية الكاملة. بغية مقارنة النجوم التي ستصنّف مع تلك الموجودة في البيان المصور المرجعي، من الضروري تعميم كافة الأطياف، وعزل المكون المستمر (التأثر بالتحمير البني النجمي). وفقط بعد ذلك، يكمن أن تُركزّ المقارنة على معلومات الخطوط الطيفية. يجب أن يتم عند تلك النقطة، تقييس الأطياف المُوحّدة لجعل مقاديرها مكافئة لنجوم البيان المصور المرجعي.

على أساس الأطياف المُقيسة والمُعممّة، يحاول الخبراء البشر تحديد النوع الطيفي والسطوعية في النظام MK. هم يقيسون ويدرسون العلاقة بين بعض خطوط الامتصاص وعمق بعض الروابط الجزئية ذات الصلة، وكنتيجة يحصلون على التصنيف الأولي لكل نجم. يعقد التحمير البني

النجمي استخدام شكل الكمية المتصلة (الاستمرارية) لتحديد درجة حرارة الفعالية الفوتوسفيرية (سطح الشمس النير). تُقاس درجات الحرارة بمعايرة الشدة النسبية للخطوط الطيفية الفردية غالباً من الانتقالات الطاقية الذرية H وHe. بالإضافة إلى ذلك، يمكن أن تُستخدم مجموعات متنوعة من الخطوط (على سبيل المثال، الكبريت أو النتروجين)، لتحديد الكثافات الالكترونية/الضغوط، وخصائص فيزيائية أخرى. تعكس عروض الخطوط السرعات الدورانية، أو التشتت السرعوي، أو الاضطراري الصُغري، وتظهر الإزاحات الخطية بتأثير دوبلر السرعة الشعاعية النجمية.

يُنقى التصنيف MK الأولي بتراكب الأطياف غير المُصنفّة وتلك من السياق المصور المرجعي الموافق لنفس النوع الطيفي، حتى يتم أخيراً تحديد النوع الفرعي الطيفي.

بالرغم من أن هذه الطريقة اليدوية للتصنيف قد اُستخدمت بنجاح لعدة سنوات، فإنها لم تعد عملية، بما أن تقنيات التجميع الحالية بالحصول على كمية ضخمة من المعطيات الطيفية خلال زمن قصير نسبياً إن التصنيف اليدوي لكافة الأطياف، المتوفرة حالياً، يتضمن زيادة كبيرة بالزمن والموارد البشرية. وبالتالي، فمن المُستحسن إلى حد كبير أَمْثَلة الأجراء اليدوي بواسطة تقنيات آلية، سريعة، وحسابية كفوءة.

تم خلال السنوات القليلة الماضية تركيز البحث في مجال التصنيف الطيفي إما على الحاجة لتطوير أدوات آلية، أو على تنقيح وتحسين التقنيات اليدوية.

أما بالنسبة لتطبيقات تقنيات الذكاء الصنعي في تصميم أنظمة تصنيف آلية، فقد طبقّت أيضاً بعض الأعمال السابقة المشهورة الشبكات العصبونية الصنعية على مسألة التصنيف النجمي (Weaber, 1995; Gulati, 1998)، التي حصلت على تصنيفات بدرجات تمييز متنوعة.

ساهم فريق بحثنا في خط البحث هذا بتطوير أنظمة خبيرة عائمة متنوعة من أجل تصنيف النجوم العملاقة جداً، والعملاقة، والصغيرة جداً (القزمة). يمكن إيجاد وصف كامل لأعمالنا السابقة في Rodriguez (2004). قادتنا النتائج المكتسبة لتمديد هذه الأنظمة إلى نجوم من سطوعيات مختلفة، وإضافة تقنيات حسابية جديدة، كالشبكات العصبونية الصنعية وخوارزميات العنقدة، بغية تنقية المعالجة الآلية للأطياف.

لا يكمن هدفنا الحالي في اختيار النماذج أو التقنيات، التي تم للتو عرض ملاءمتها لهذه المسألة، وإنما بدلاً من ذلك، دمج كافة التقنيات في أداة تصنيف وحيدة. إننا ننوي تشكيل نظام هجين، يكون قادراً على تحديد الطريقة الأكثر ملاءمة لكل نوع طيفي، وللحصول على تصنيفات MK فورية من خلال قاعدة معطيات نجمية على شبكة الانترنت (http://starmind.tic.udc.es).

تبدأ الأقسام التالية بوصف المعطيات الطيفية، التي اُستخدمت لتصميم واختبار تقنيات التصنيف الآلية. بعد ذلك، نصف خوارزميات التحليل التكويني، التي طُبقت على الأطياف قبل تقديمهما إلى التقنيات الآلية. أخيراً، نقدم نماذج الذكاء الصنعي المختلفة، التي طُبقت، ونباين نتائجها.

المعطيات الفلكية

اخترنا مجموعة كاملة ومنسقة من 258 طيفاً، بحيث تغطي كافة الأنواع والسطوعية لنظام MK، بغية تصميم النماذج الصنعية، التي سوف تُطبق على مسألة التصنيف. إن هذه المجموعة تمثيلية بما فيه الكفاية، لأنها تقدم انتقالاً مستمراً من السمات الطيفية بين كل نوع طيفي وأنواعه المجاورة. حُللت مسبقاً الأطياف المختارة، وصُممت من قبل الخبراء البشر المشاركين في هذا المشروع. لقد استخدمنا البيانات المصورة للباحث Silva (1992) وهي – 28 طيفاً أُخذت عيناتها في المجال من 3500 إلى 8900 Å بتمييز طيفي مقداره 5 Å – وللباحث Pickles (1998) وهي 97 طيفاً أُخذت عيناتها في المجال من 1150 إلى 25000 Å بتمييز طيفي مقداره 5 Å، وللباحث Jacoby (1984) وهي 133 طيف أُخذت عيناتها في المجال من 3510 إلى 7426 Å بتمييز طيفي مقداره 1.4 Å.

التحليل التكويني

إن الأنماط، التي قُدّمت إلى النماذج المختارة، قد حُصل عليها آلياً بواسطة تقنيات معالجة الإشارة، التي تقيس الخواص الطيفية (خطوط الامتصاص والإصدار، الطاقة الطيفية، الروابط الجزيئية ... الخ). وبشكل خاص، تقيس السمات الطيفية الـــ 25 الموصوفة في (الجدول 2). يمكن أن تُجمّع هذه البارامترات الطيفية إلى ثلاثة أنواع هامة:

- خطوط الامتصاص والإصدار: متضمنةً خطوط الهيدروجين والهليوم والخطوط المعدنية (Ca، K، Fe، ...الخ).
- الروابط الجزيئية: روابط امتصاص الهيدروجين والكربون.
- النسب بين الخطوط: النسب CH-K، النسب He-H.... وهلم جراً.

تعتمد بشكل رئيسي خوارزميات معالجة الإشارة، المستخدمة للحصول على البارامترات الطيفية، على تقدير الاستمرارية الطيفية والقياس الطاقي.

ومن وجهة نظر تكوينية، فإن أي خط امتصاص هو هبوط (صعود من أجل الإصدار) قمة (ذروة) عميقة، تظهر في منطقة طول موجة مؤسّسة. ولحساب الشدة بدقة لكل خط، نجري عملية تقدير للاستمرارية الطيفية المحلية. ننعم الإشارة بمرشح تمرير منخفض باستبعاد الذرى في المجال حول العينة، حيث أُكتشف الخط. هذا المرشح مُنفذ بطريقة المتوسط المتحرك خماسي النقط، التي تختار التدفقات الخمس الأكثر استقراراً.

الجدول (2) بارامترات التصنيف الطيفية

البارامتر	الوصف
الرابطة 1	Å 055 ± 5005
الرابطة 2	Å 150 ± 6225
الرابطة 3	Å 070 ± 4435
الرابطة 4	Å 180 ± 5622
الرابطة 5	Å 135 ± 5940
الرابطة 6	Å 040 ± 6245
الرابطة 7	Å 130 ± 6262
الرابطة 8	Å 100 ± 6745
الرابطة 9	Å 050 ± 7100
الخط (K) Ca II	Å 3935
الخط (H) Ca II	Å 3968
خط الرابطة CH	Å 4300
الخط Iγ H	Å 4340
الخط Iδ H	Å 4102
الخط I He	Å 4026
الخط II He	Å 4471
الخط Iβ H	Å 4861
الخط Iα H	Å 6563
الروابط الرئيسية	$\sum_{i=1}^{i=2}$ الرابطة i
الروابط الثانوية	$\sum_{i=3}^{i=9}$ الرابطة i
النسبة K - H	Ca H K/Ca II H
النسبة CH - H Iγ	الرابطة H Iγ/CH
النسبة H Iδ - HeI	H Iδ/He I
النسبة H Iδ - He II	H Iδ/He II
الطاقة	تكامل التدفق

أي:

$$C_j = \frac{\sum_{j-n}^{j+n} E_i * X_i}{N} \quad (1)$$

حيث أن: C_j – تقدير استمرارية العينة j. E_i – التدفق في العينة i. N – عدد القيم المستخدمة في طريقة المتوسط المتحرك لحساب الاستمرارية الطيفية المحلية. X – شعاع ثنائي، يشير إلى التدفقات التمثيلية للاستمرارية الطيفية في المنطقة. وهذا يعني بأن $X_i = 1$، إذا كان E_i هو ممثل قيمة تدفق الاستمرارية الطيفية المحلية. و$X_i = 0$، إذا كان E_i هو ذروة. وتكون الشدة موجبة من أجل خطوط الامتصاص، وسالبة من أجل خطوط الإصدار.

أي رابطة جزيئية هي منطقة طيفية ينخفض فيها التدفق فجأة من الاستمرارية المحلية أثناء مجال طول موجي عريض. ومن أجل الروابط الجزيئية، فإن هذا يعني، بأنه يتوجب علينا فقط قياس طاقتها لتقرير ما إذا كانت مهتمة بما فيه الكفاية. في هذه الحالة، يُحسب خط العينة العلوي لكل رابطة بواسطة الاستيفاء الخطي بين التدفقات في حدود المجال المُعرّف لكل رابطة. ثم تُحسب المساحة بين هذا الخط ومحور السينات بتكامل منفصل، وتُحسب المساحة، التي تحيط بكل رابطة، بتكامل إشارة التدفق بين نهايات الرابطة. أخيراً، يتم الحصول على تدفق الرابطة بطرح كلا الطاقتين المحسوبتين، أي:

$$B_{er} = \int_e^r L(\lambda_i) - \int_e^r E(\lambda_i) \quad (2)$$

حيث أن: B_{Lr} – تدفق الرابطة بين العينات L وr. L – خط الإسقاط. E – تابع التدفق. λ – الطول الموجي. e – الحد الأيسر للرابطة. r – الحد الأيمن للرابطة.

بما أن القيم المكتسبة تصبح سلبية أكثر كلما أصبحت الرابطة أعمق وأوسع، فإن القيم الموجبة أو السالبة القريبة من الصفر لا تُعتبر كروابط.

تقنيات التصنيف

من بين التقنيات الموجودة للذكاء الصنعي، تبدو النظم الخبيرة (ES) والشبكات العصبونية الصنعية (ANN) أكثر ملاءمة لمعالجة مسألة التصنيف النجمي. إذ تستطيع النظم الخبيرة إعادة إنتاج استنتاج الخبراء بغية تصنيف الأطياف. وقد أثبت الشبكات العصبونية – القادرة على تعلمّ العلاقات الداخلية للأنماط، التي تم تدريبها عليها – فعاليتها في مسائل التصنيف (Bazoon, 1994).

كما طبقنا أيضاً خوارزميات العنقدة لتنفيذ التحليل الإحساسي لأطياف الدخل، بالرغم من أن هذه التقنية لا تُستخدم حالياً للحصول على تصنيفات MK للنجوم.

يكمن هدفنا في دمج كافة التقنيات المُصممة والمُطبقة في نظام هجين فريد قادر على تطبيق طريقة التصنيف الأفضل لكل طيف دخل. يتضمن النظام المُطّور أداتين مختلفتين: محللاً طيفياً ومُصنّفاً نجمياً.

يقوم المحلل الطيفي بتحليل تكويني شامل للأُطياف باستخدام الخوارزميات الموصوفة للحصول على تمثيل بارامتري عددي. وهو مُطّور في لغة (Builde C++) (Hollingworth, 2000)، ويدمج مكونات Active X الخاصة من أجل تصّور الأطياف.

يسترجع المحلل المعطيات الطيفية من قاعدة معطيات علائقية، تخزن وتبني المعلومات من المصادر البشرية والببليوغرافية (مَسْرد بالكتب). تُطبق قاعدة المعطيات النجمية عن طريق نظام إدارة قاعدة المعطيات Postgre SQL العامل تحت لينكس Linux (Momjiam, 2000). يوجد حالياً حوالي 400 طيف من مسحنا مخزنة في قاعدة المعطيات، وسوف تكون متاحة قريباً بواسطة شبكة الانترنت.

يعتمد المُصنّف النجمي على تطوير النماذج الصنعية المختلفة، التي أُختيرت لمعالجة MK للنجوم. استخدمنا كلتا البارامترات المكتسبة بواسطة المحلل الطيفي، والمعطيات الطيفية الكاملة، لبناء أنماط الدخل لتقنيات الذكاء الصنعي. طُبقت الشبكات العصبونية بمقلد Stuttgart للشبكات العصبونية (SNNS, 2001)، وطوّرت خوارزميات العنقدة بلغة الـ MatLAB الإصدار (Hahn, 2002). ونُفذت النظم الخبيرة في OPS/R2 (Forgy, 1986).

نقوم حالياً بتطوير موقع ويب، سيجعل المُصنّف النجمي متاحاً عبر شبكة الانترنت. وهدفنا الرئيس هو السماح للمستخدمين بتصنيف أطيافهم النجمية مباشرة بأسلوب مريح، فعال وسريع.

بعد تحليل أداء كل تقنية بشكل منفصل، نفذنا النماذج الأفضل في لغة C ++ بمكاملتها مع محلل طيفي، يزودنا بأداة وحيدة لمعالجة وتصنيف الأطياف البصرية للنجوم.

يصف القسم التالي النماذج المختلفة، التي تُكامّل مع المُصنّف الطيفي النجمي.

النظم الخبيرة

تقترح الطريقة الأولى تنفيذ نظام معتمد على المعرفة، يزود المستخدم بأداة مريحة لمعالجة الأطياف النجمية. لقد كاملنا تقنيات معالجة الإشارة، والتقنيات المعتمدة على المعرفة، والتقنيات العائمة، التي تعطي محاكاة مقنعة جداً للعملية اليدوية الحالية. إن نظامنا الأخير قادر على تصنيف النجوم بمعدل نجاح قريب جداً للنسبة المئوية الموافقة بين الخبراء في هذا المجال (حوالي 80%)، وتسمح

لقيدي تصنيف: الأطياف بدون أي صف سطوعية معطى، وأطياف النجوم بمستوى سطوعية معلوم جيداً.

وكخطوة سابقة باتجاه تصمي النظام الخبير، نفذنا تحليل حساسية لبارامترات التصنيف بغية تعريف المجموعات العائمة المختلفة، والمتغيرات، والتوابع العصبونية. قمنا في هذه الدراسة بتحليل بارامترات الأطياف من بيان المصور المرجعي باستخدام الخوارزميات المذكورة أعلاه، وبتحديد الأنواع الطيفية المختلفة، التي يميزها كل بارامتر. ونُبذت بعض البارامترات التي تبدو مناسبة، بينما تم تضمين البارامترات الأخرى، التي لم تُعتبر بشكل واضح في التصنيف اليدوي، على سبيل المثال، إضافات تدفقات الروابط: لم يتم إيجاد أي رابطة جزيئية – بنفسها – مناسبة لتحديد درجة الحرارة العامة من أجلٍ كافة النجوم (بدائية، متوسطة، وحديثة) في البيان المصور المرجعي. على أية حال، وجدنا تمييزاً جيداً بين النجوم البدائية، والمتوسطة، والحديثة، التي تكون إضافة عدة روابط ذات صلة. يمكن أن يقسم هذا البارامتر النجوم من البيان المصور إلى ثلاثة مجموعات درجة حرارة عامة. بما أن بعض النجوم، التي تنتمي إلى مجموعة ما، تبدي قيمة كبيرة في بعض الروابط، وفي بعض النجوم الأخرى توافق القيمة الأعلى رابطة مختلفة، فإن الإضافة تحل هذه المشاكل.

كنتيجة نهائية لهذا التحليل، قمنا بتعريف متغيرات عائمة عديدة بقدر مستويات التصنيف (عامة، توعية، ونوعية فرعية) لكل صف سطوعية. كما عرّفنا أيضاً المجموعات العائمة وتوابع العضوية المُحددة بقيم السمات الطيفية في أطياف البيان المصور المرجعي.

يخزن النظام الخبير المُطوّر المعلومات، التي هي ضرورية للبدء بعملية الاستنتاج والتعليل في قاعدة الحقائق. تُمثل هذه المعرفة الوصفية للأطياف بواسطة الإطارات (Sowa, 1999)، أي، أغراض وخصائص مبينة بمستويات. اُختير هذا النموذج، لأنه الأبسط والأكثر ملاءمة لنقل معطيات التحليل إلى وحدة التصنيف، ويسمح لنا بتأسيس التكافؤ بين معطيات التحليل والمعرفة. تتضمن قاعدة الحقائق معلومات عامة مثل أسماء النجوم ونتائج التحليل التكويني، أي، قيم بارامترات التصنيف.

تم تضمين البارامترات الحقيقية للتصنيف الطيفي والقيم الحدية لكل نوع، ولكل نوع فرعي في النظام الخبير في صيغة قواعد عائمة. إن أساس القواعد هو جزء من النظام، حيث يُعاد إنتاج معايير التصنيف البشري. وقد اخترنا قواعد الإنتاج IF-THEN لتطبيق هذه الوحدة، لأنها تسمح بإدارة الشك والتفحص اللذان يميزا الاستنتاج البشري في هذا المجال.

تشير شروط هذه القواعد إلى قيم البارامترات المخزنة في أساس الحقائق الحالي (الذاكرة العاملة). تلّمح الاستنتاجات إلى ثلاثة مستويات من التصنيف الطيفي: عام (بدائي، متوسط، حديث)، النوع الطيفي، والسطوعية، وبحد ذاته تتصل الوحدة بشكل فعّال بأساس الحقائق.

لتقرير ما القاعدة التي تطبق في كل لحظة، استخدمنا استراتيجية تحليل طرف الوسائل (MEA) (Valette - Florence, 1994). أساساً، من بين القواعد التي دُمجت مؤخراً إلى الذاكرة العاملة، تختار الاستراتيجية القاعدة غير المُنفذة، التي لها العدد الأكبر من الأنماط. تُربط قواعد الإنتاج في تعليل أمامي موّجه بالأهداف. تدمج هذه الاستراتيجية المستخدمة من أجل عملية التعليل طرق التعليل الموجه مع طريقة معتمدة على قيم الحقيقة. وكما تمت مرافقة القواعد أيضاً بعوامل المصداقية، التي حُصل عليها من المقابلات مع الخبراء ومن المَسْرد بالكتب لهذا المجال.

استخدمنا منهجية الباحثين Shortliffe وBuchanan (Buchanan, 1984) لخلق تطور، يتضمن المجموعات العائمة والتوابع العضوية، التي تُكّون من أجل كل نوع طيفي، وتسمح بالتراكب بينها. طريقة الاستدلال المُطبقة هي إنتاج الأعظم، التي تدمج تأثير كافة القواعد الفعّالة، وتنتج خرجاً مستمراً ناعماً. تم في طريقتنا الأخذ بالاعتبار عامل المصداقية لكل قاعدة كقيمة حقيقية أخرى. أُنجزت عملية فك تعويم المعطيات إلى خرج متموج بطريقة المركز العائم (Mendel , 1995). بهذه الاستراتيجية المختلطة، حققنا تكّيفاً ملحوظاً لعملية التعليل البشري قادر بنجاح على معالجة الغموض والشك المتضمنين في عملية التصنيف اليدوية. بالإضافة لذلك، حصلنا على التصنيف الطيفي للنجوم بقيمة احتمالية، تشير إلى درجة الثقة. طُوّر هذا الجزء من المُصنّف الطيفي في OPS/R2 (Forgy, 1986)، وتمت مكاملة بالمحلّل بواسطة مكتبات ربط ديناميكية (DLL).

تضمن موضوع البحث الإضافي في تحسين النظام المُنفذ بتطبيق نتائج النماذج العصبونية الأفضل، وسوف نشرحه في الأقسام اللاحقة. حُلّلت أوزان طبقة الخرج، لكي تُحدد - من أجل كل نوع طيفي - أي بارامترات الدخل لها تأثير أكثر على الخرج. تم تضمين القيم المُعممة للأوزان الأعلى في النظام الخبير في صيغة عوامل مصداقية القواعد، التي توافق البارامترات الأكثر تأثيراً لكل نوع طبيعي. أدى هذا التعديل لقواعد التعليل (باستخدام قيم الأوزان للشبكات العصبونية المدربة) إلى تحسين هام بعض الشيء لأداء الأنظمة الخبيرة الأصلية (حوالي 2%).

الشبكات العصبونية الصنعية

تعتمد الشبكات العصبونية لهذه الطريقة على كل من نماذج التعلّم المُراقب وغير المُراقب (Haykin, 1994). وبشكل خاص، تم تطبيق شبكات خلفية الانتشار، Kohonen، والتوابع الأساسية الشعاعية (RBF).

لقد اختبرنا ثلاثة خوارزميات تعلّم خلفية الانتشار (قياسية، زخم، وسريعة) لكل الأنواع الطيفية: الأنواع الفرعية الطيفية، وصفوف السطوعية. كما اختبرنا أيضاً شبكات RBF والشبكات المعتمدة على التوابع الأساسية الشعاعية التي تجمع التعلّم غير المُراقب للوحدات الخفية والتعلّم المُراقب في

طبقة الخرج. تطبق العصبونات الخفية تابعاً شعاعياً (بشكل عام تابع غاوس) على المسافة، التي تفصل شعاع الدخل وشعاع الوزن، بحيث يخزن كل واحد والمسمى بالمركز.

أخيراً، طبقنا أيضاً شبكات Kohonen. تعتمد خوارزمية الخريطة ذاتية التنظيم (SOM) لـ Kohonen على التعلّم غير المُراقب. إن شبكات SOMs هي صف فريد من الشبكات العصبونية، بما أنها بنت طبولوجية، تحافظ على نقل معطيات التدريب، حيث يحمل موقع أي وحدة معلومات ذات دلالة (Kohonen, 2001).

تم الحصول على أنماط التدريب وإثبات الصلاحية والاختبار، التي تُقدّم إلى الشبكات العصبونية، آلياً بإضافة التوابع الضرورية للمحلل الطيفي المُطوّر في طريقة النظم الخبيرة. حينما يتم الحصول على قيم الدخل بواسطة المحلل الطيفي، يجب أن يتم تعميمها وتقديمها إلى الشبكات العصبونية. تُوحد دراستنا مدخلات الشبكة بواسطة تابع سيغمويد معين تكويني لكل بارامتر. يُعمم هذا التابع بارامترات الدخل في المجال [0، 1]، ويُمركز، ويقيّس التابع التوزيعي لكل بارامتر بشكل لائق. الطبولوجيات المختلفة، التي طُبّقت لخوارزميات التعلّم الثلاث مبينة في (الجدول 3).

الجدول (3) الطبولوجيات المُختبرة من أجل شبكات الانتشار الخلفي، Kohonen وRBF (* تبين الشبكات الأفضل).

الشبكة	أنماط الدخل	الطبقة الخفية
النوع BP	بارامترات طيفية	10
النوع BP	بارامترات طيفية	5 × 5
النوع BP	بارامترات طيفية	10 × 10
النوع BP	بارامترات طيفية	10 × 5 × 3*
النوع BP	659 قيمة تدفق	100 × 50 × 10 × 3
سطوعية BP	بارامترات طيفية	10 × 10
سطوعية BP	659 قيمة تدفق	100 × 50 × 10 × 3
النوع RBF	بارامترات طيفية	16
النوع RBF	بارامترات طيفية	8*
النوع RBF	بارامترات طيفية	4
النوع RBF	659 قيمة تدفق	124
سطوعية RBF	بارامترات طيفية	8
سطوعية RBF	659 قيمة تدفق	124
النوع Kohonen	بارامترات طيفية	2 × 2
النوع Kohonen	بارامترات طيفية	12 × 12*
النوع Kohonen	بارامترات طيفية	24 × 24
سطوعية Kohonen	بارامترات طيفية	2 × 2

تظهر ملاحظاتنا لسلوك الشبكات، بأنها تتقارب عندما يكون الخطأ التربيعي المتوسط (MSE) مساوياً أو أدنى من 0.05، وتصبح الشبكة مستقرة. وإذا استمر التدريب بعد الحصول على هذه النسبة من MSE، فإن الشبكة تصبح مدربة أكثر من اللازم، وينخفض أداؤها. في المقلد SNNS المُستخدم لتدريب الشبكات، أي خرج أكبر من 0.5 يكافئ 1 وإلا فهو 0. لم نعتبر أثناء تحليل النتائج المخرجات القريبة من 0.5 كنجاحات (من 0.45 وحتى 0.55).

إن طبولوجية الانتشار الخلفي، التي أعطت أداء أفضل توافق شبكة مدربة بـــ 25 بارامتر طيفي كطبقة دخل وثلاثة طبقات خفية من 10، 5 و3 وحدات. تم إنجاز النتائج الأفضل لشبكات Kohonen بخرائط من 12 ×12 وحدة. أما بالنسبة لشبكات RBF، فإن الطبولوجية الأفضل توافق شبكة مدربة بـــ 25 بارامتر طيفي كطبقة دخل و8 عصبونات في الطبقة الخفية.

تقنيات العنقدة

بغية تنقية التصنيفات المُشكلة بالشبكات العصبونية الصنعية والنظم الخبيرة، نفذنا تقنيات عنقدة إحصائية، وطبقناها على مسألة التصنيف الطيفي. وبشكل خاص، نفذنا طريقة المتوسطات – K، الأصغر – الأعظم، وطرق العنقدة غير التسلسلية الهرمية متساوية المعطيات (Kaufman, 1990). تستخدم هذه الطريقة البارامترات الطيفية، التي تم الحصول عليها بخوارزميات التحليل التكويني، بالإضافة إلى كامل الأطياف. بالإضافة لذلك، تم تطبيق إصدارين مختلفين لكل خوارزمية بـــ 6 و12 من العناقيد الابتدائية.

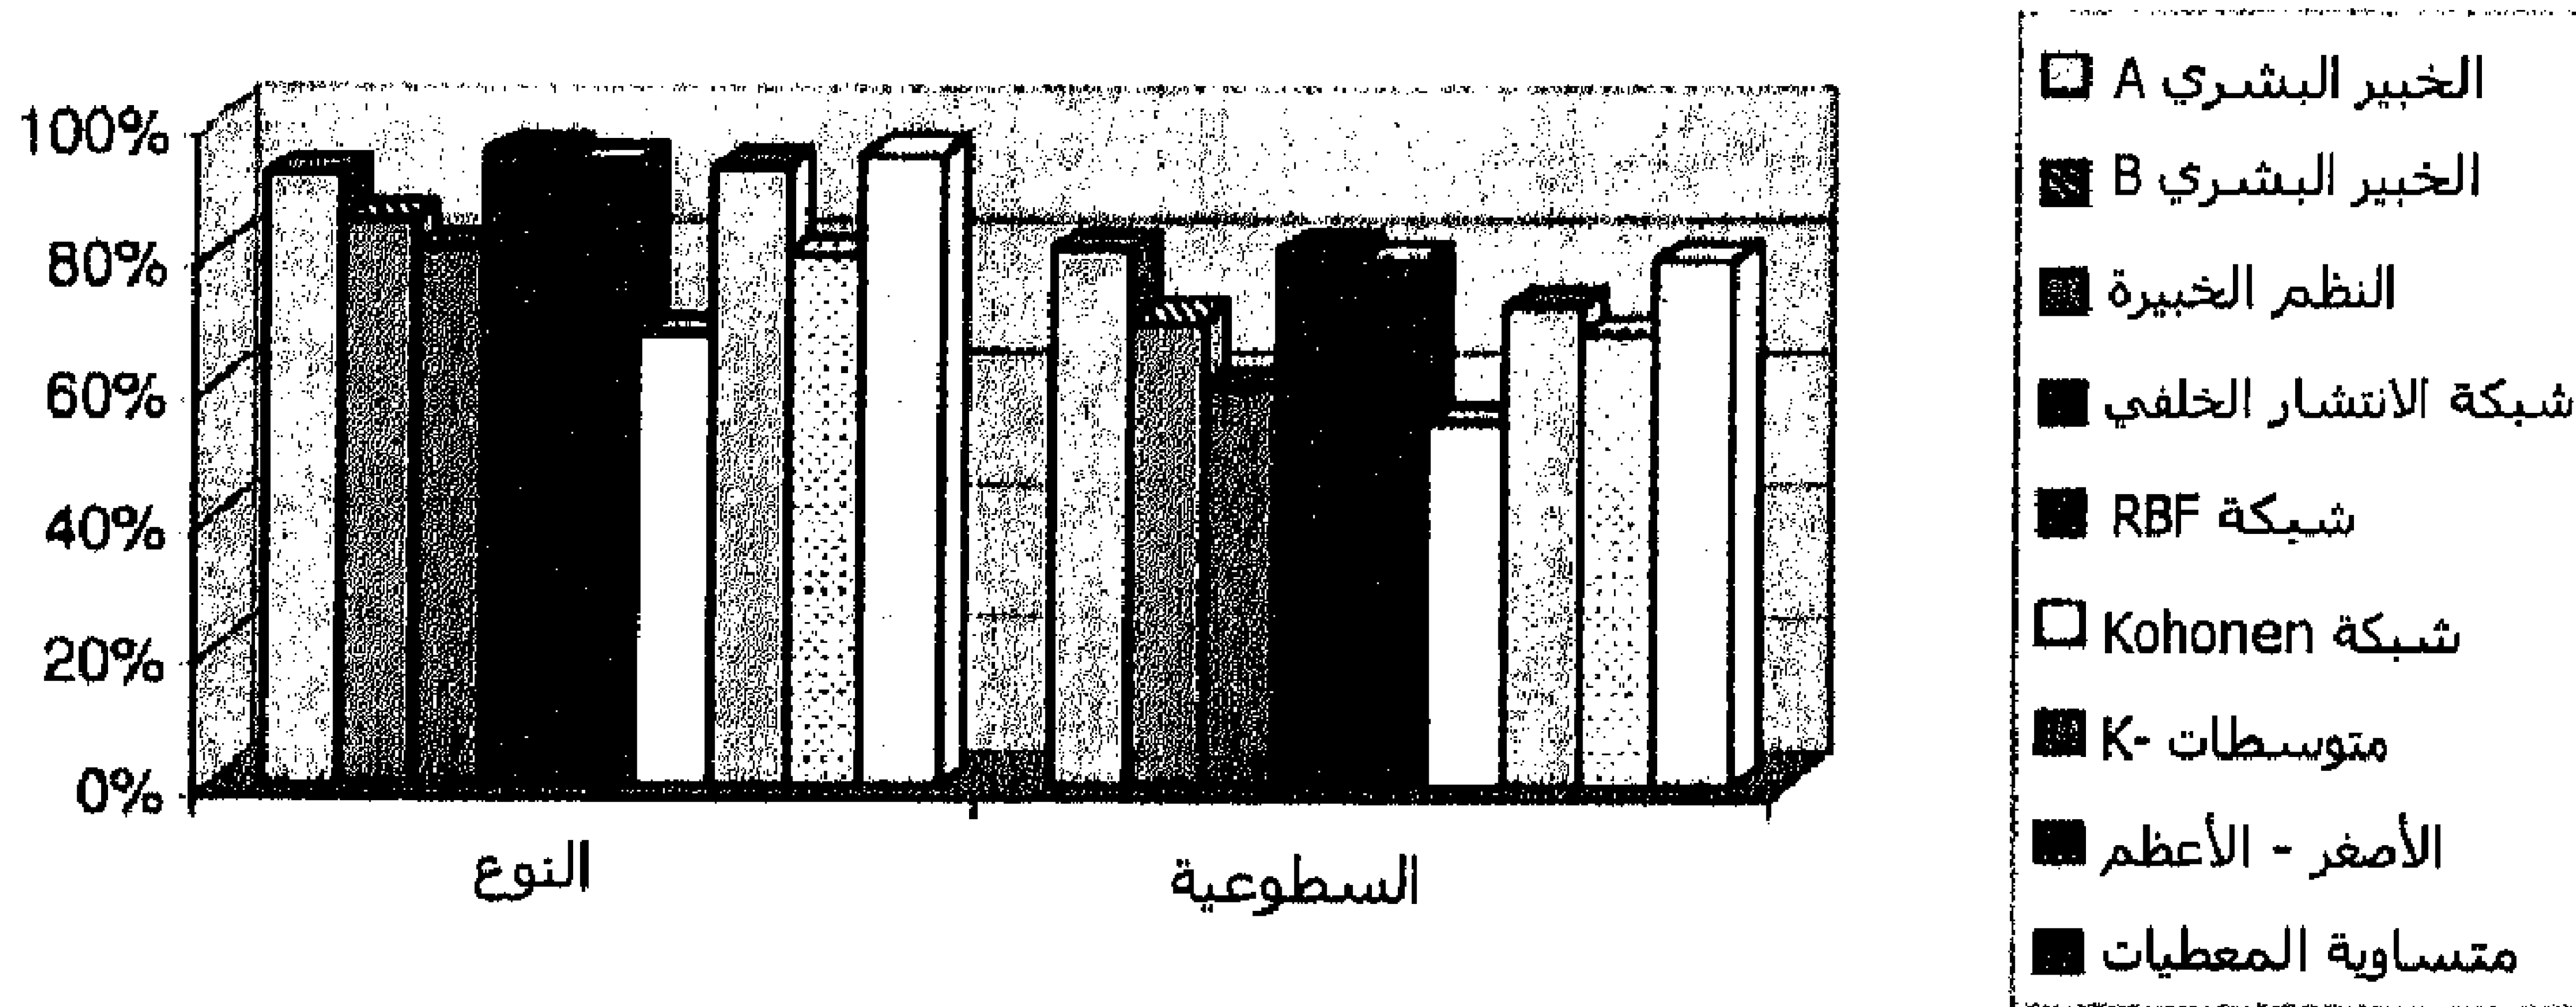
بالرغم من أن طرق العنقدة المُطبقة قد أنجزت معدلات نجاح رائعة في تصنيف الأطياف النجمية، فإن هذه التقنية طُبقت بشكل أساسي لتحليل حساسية البارامترات الطيفية، التي استخدمت لتصنيف الأطياف النجمية.

النتائج

يشكل هذا القسم مقارنة نهائية بين الطرق العامة المُطبقة الثلاث: النظم الخبيرة، تقنيات العنقدة، والشبكات العصبونية الصنعية. لقد اخترنا النماذج العصبونية لكل نوع بالأداء الأفضل، وصنّفنا بواسطة خوارزميات العنقدة والنظم الخبيرة الأطياف الـــ 100، التي استُخدمت لاختبار هذه الشبكات. يبين (الشكل 1) سلوك التقنيات الآلية وسلوك خبيرين من البشر المشتركين في هذا المشروع. حصلت شبكات الانتشار الخلفي وشبكات RBF، بالإضافة إلى خوارزميات المتوسطات – K ومتساوية المعطيات، على معدل نجاح عالي حوالي 95%. وحصل نموذج Kohonen على معدل نجاح منخفض في كافة تطبيقاته، ما يمكن أن يكون ناتجاً عن حجم مجموعة التدريب.

هذا النوع من الشبكات يجب أن يجمع المعطيات على شكل عناقيد. وبالتالي، فهو يحتاج لمجموعة تدريب كبيرة كفاية لاستخلاص التشابهات وتجميع المعطيات.

الشكل (1) الأداء النهائي لـ 100 طيف اختبار

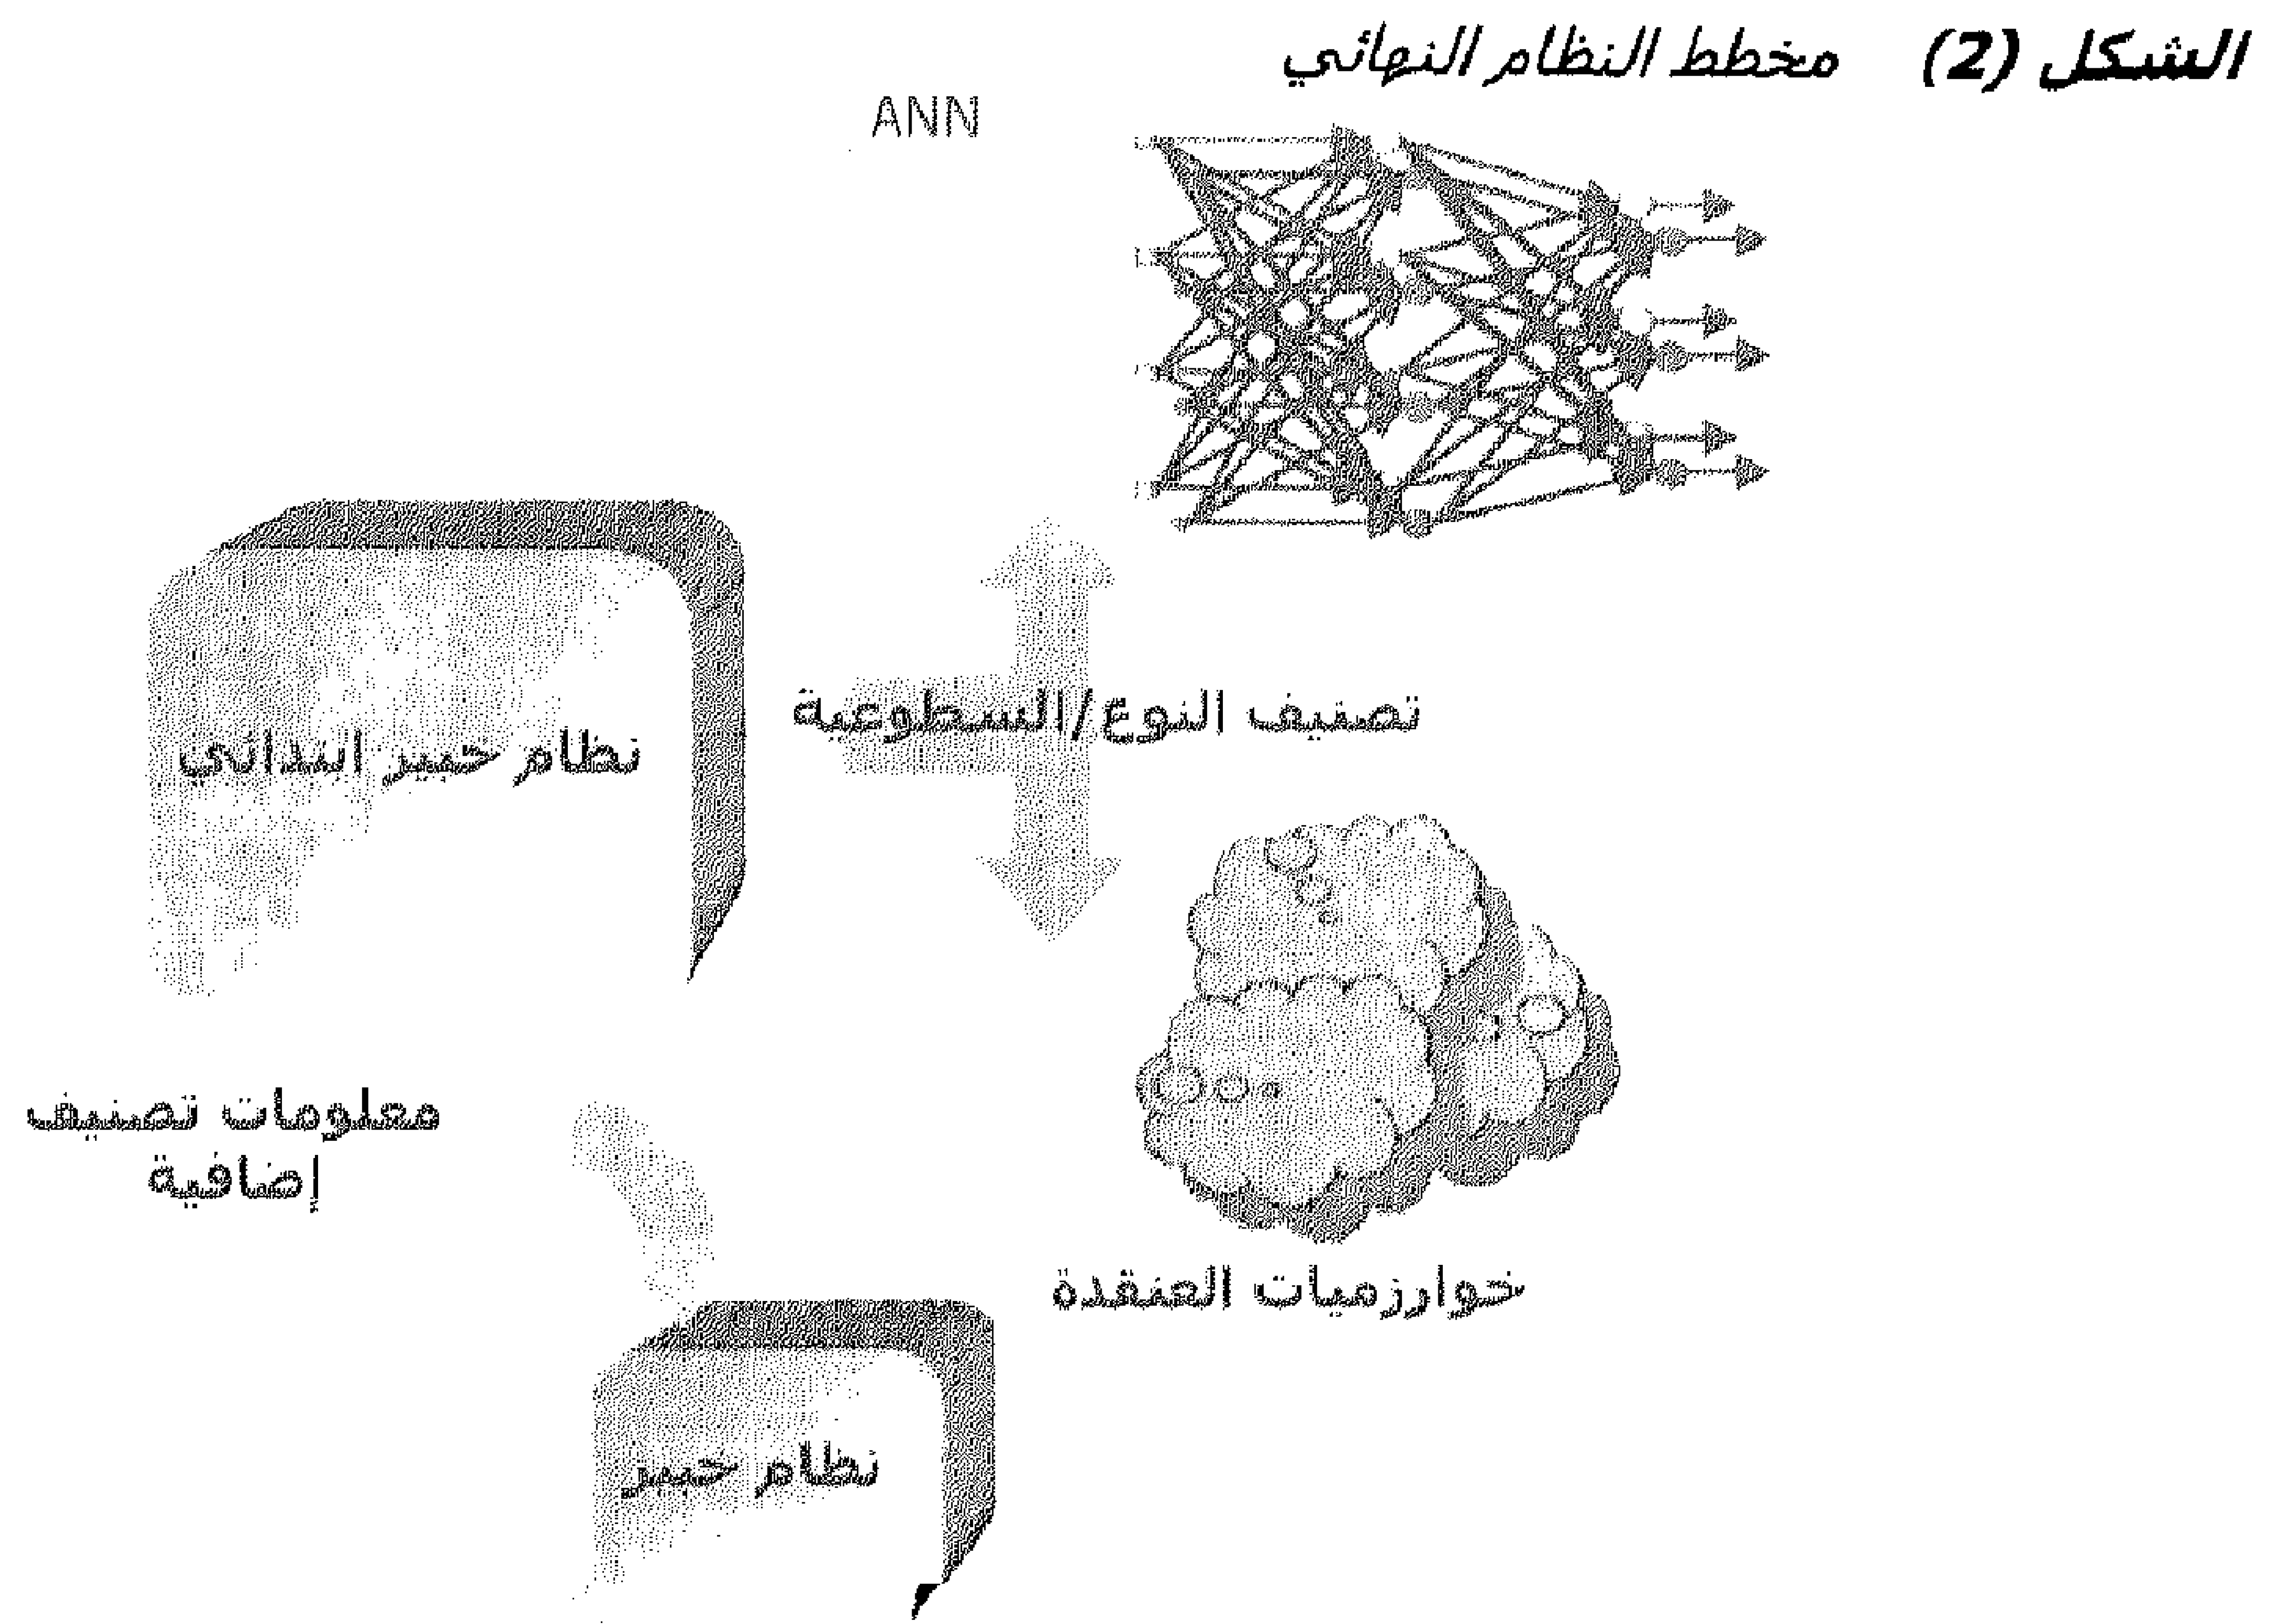


على الرغم من أن النتائج النهائية لطرق التصنيف المقترحة تبدو متشابهة، فقد كشفت دراسة شاملة بعض الخواص المثيرة. على سبيل المثال، لاحظنا بأن كل تقنية وصلت إلى نتائجها الأسوأ من أجل الأنواع الطيفية B وM، أي النجوم الأسخن والأبرد على الترتيب. وفي الواقع، تتضمن غالبية خوارزميات التجميع هذه الأطياف في نفس العنقود. تقودنا هذه الحقيقة إلى مراجعة البارامترات الطيفية، التي استخدمت لتصميم النماذج: واكتشفنا بأن النجوم B، تقدم عادة خطوط إشعاع كبيرة في المناطق حيث يُتوقع رابطة جزيئية، ما يعني بأن التقنيات الآلية غير قادرة على التفريق بينها. تحاول طريقتنا الهجينة حل تلك المسائل بالقيام بتصنيف عام سابق لنجم، ومن ثم اختيار الطريقة الأفضل لتصنيف الأطياف.

الاستراتيجية الهجينة

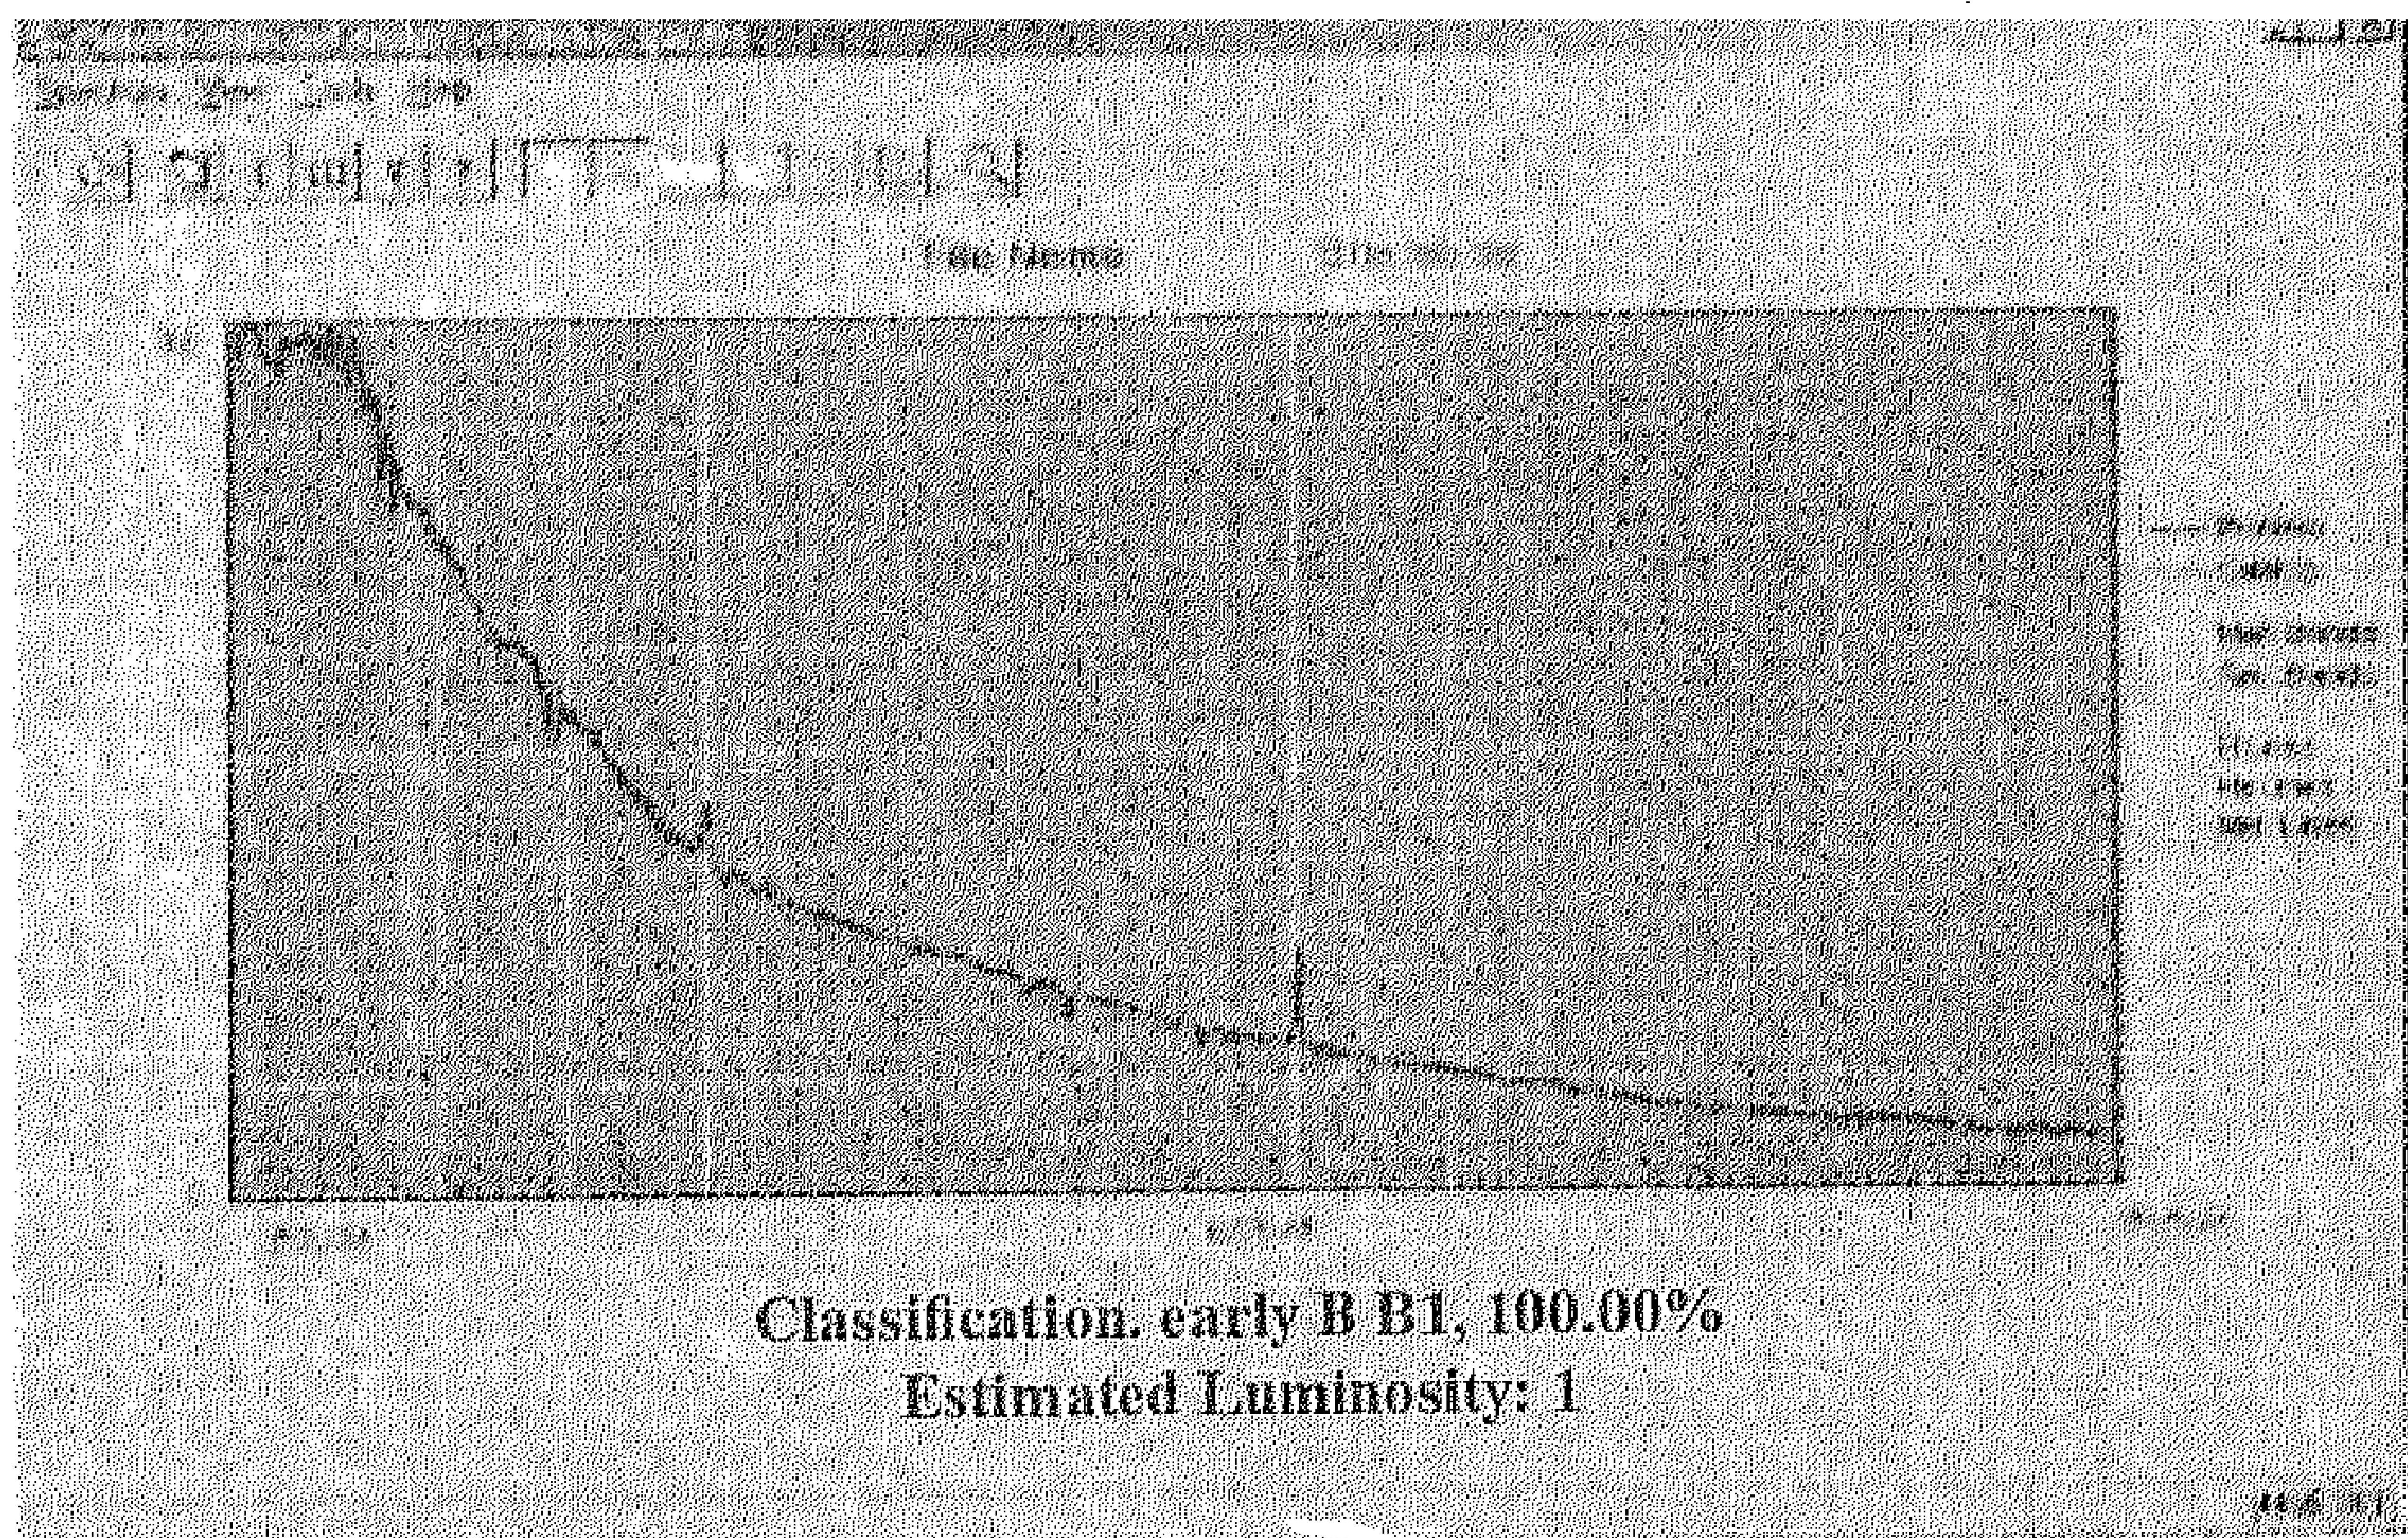
تتألف طريقتنا الهجينة من اختيار تلك الطرق التي تقدم الأداء الأفضل لكل مستوي تصنيف من بين كافة التقنيات الموصوفة. يعتمد النظام النهائي بشكل أساسي على نظام خبير، يحدد النوع العام لكل نجم، والذي – وفقاً للنوع – يرسل الأطياف إلى شبكات عصبونية مختلفة، أو خوارزميات عنقدة، بغية الحصول على نوعها الطيفي بالإضافة إلى مستوي سطوعيتها. يُستخدم أيضاً تصنيف النظام الخبير كمعلومات إضافية من أجل تلك الحالات، التي لا تكون فيها الطرق الأخرى قادرة على التمييز. النموذج المفاهيمي للنظام النهائي مبين على (الشكل 2).

الشكل (2) *مخطط النظام النهائي*



يتضمن النظام المُنفذ النهائي واجهة تطبيق ودودة مبينة على (الشكل 3). فهي تسمح للمستخدمين باختيار الأطياف وإبصارها، تنفيذ تحليلات مختلفة، وتصنيف العديد من الأطياف بقدر ما يريدون بطريقة بسيطة، مريحة وسريعة، وهو الهدف العام لهذه الطريقة الحسابية.

الشكل (3) *واجهة تطبيق النظام النهائي.*



الاستنتاج

اقترح هذا الفصل طريقة هجينة وتعاونية لمسألة التصنيف MK للنجوم. تعتمد مساهمتنا على تطوير نظام غير موجود، يحلل بشكل تكويني ويُصنّف آلياً الأطياف البصرية للنجوم.

لقد وصفنا عدة نماذج ذكاء صنعي، وحللنا أداءها ونتائجها لاكتشاف الطريقة الأفضل لتصنيف كل نوع من الطيف. في بحثنا، دمجنا تقنيات معالجة الإشارة، والنظم الخبيرة، والشبكات العصبونية، وخوارزميات العنقدة.

وصلت أفضل التقنيات إلى معدل نجاح 95% لعينة من 100 طيف اختبار الذي، بالمقارنة مع التصنيفات اليدوية، يوافق لزيادة أداء بحوالي 10% (بما أن الخبراء وصلوا إلى نسبة مئوية توافقية من حوالي 87% للأطياف).

باستخدام معلومات التصنيف الإضافية المزودة بتقنيات العنقدة، نكون قد فتحنا خط بحث جديد لتنقية (تحسين) التصنيفات الآلية، وبشكل خاص من أجل الأنواع الطيفية B وM. تسمح لنا تقنيات العنقدة المُطبقة بالقيام بتحليل حساسية البارامترات الطيفية المستخدمة لتصنيف الأطياف النجمية في الشبكات العصبونية، وطريقة النظم الخبيرة.

أخيراً، تمت مكاملة كافة تقنيات الذكاء الصنعي في نظام هجين، أُنتج في طريقة آلية متعددة الاستعمال ومرنة لتصنيف الأطياف النجمية. بهذا الأسلوب، يمكن أن يُنجز النظام المقترح تكيّفاً أفضل لمسألة التصنيف، بما أن كل طيف يُعالج بالتقنية الأكثر ملاءمة وفقاً لسماته المعينة.

من أجل دور التقييم للنماذج المقترحة، يمكننا أن نعتمد على التعاون الأساسي للخبراء في مجالات علم الفلك والفيزياء الفلكية من جامعة A Coruña.

حالياً، نقوم بتحليل الشبكات التابعية بغية تحديد ملاءمة هذه التقنية الصنعية للتصنيف النجمي. كما أننا نعمل أيضاً على قاعدة معطياتنا النجمية، ونطور موقع ويب لجعل نظام التصنيف الآلي متاحاً عبر شبكة الانترنت، لكي يسمح لمستخدمي العالم الواسع بتحليل وتصنيف الأطياف مباشرةً بأسلوب مريح، فعّال وسريع.

المراجع

Bazoon, M., Stacey, D., Cui, C., & Harauz, G. (1994). A hierarchical artificial neural network system for the classification of cervical cells. Proceedings of the IEEE Interna-tional Conference on Neural Networks (1CNN '94).

Buchanan, B., & Shortliffe, E. (1984). Ruled-based expert systems. Adisson-Wesley.

Forgy, C.L. (1986). The OPS user's manual, system version 2.2. Production Systems Technologies.

Gulati, R.K., & Singh, H.P. (1998). Stellar classification using principal component analysis and artificial neural networks. Monthly Notices Royal Astronomical Society, 295. 312.

Hahn, B. (2002). Essential MATLAB for scientists and engineers. University of Cape Town.

Haykin, S. (1994). Neural networks. A comprehensive foundation. MacMillan College Pub.

Hollingworth, J., Butterfield, D., Swart, B., & Allsop, J. (2000). C++ builder 5.0. Developer's guide. SAMS.

Jacoby, G.H., Hunter, D.A., & Christian, C.A. (1984). A library of stellar spectra. The Astrophysical Journal Suppl., 56, 257-281.

Kaufman, L., & Rousseuw, P.J. (1990). Finding groups in data. John Wiley.

Kohonen, T. (2001). Self-organizing maps (3rd ed.). Springer.

Mendel, J.M.(1995). Fuzzy logic systems for engineering: A tutorial. Proceedings of the IEEE, 83(3), 345-377.

Momjiam, B. (2000). PostgreSQL: Introduction and concepts. Adisson-Wesley.

Morgan, W.W., Keenan, P.C., & Kellman, E. (1943). An atlas of stellar spectra with an outline of spectral classification. Chicago: University of Chicago Press.

Pickles, A.J. (1998). A stellar spectral flux library. 1150-25000 A. Publications of the Astronomical Society of the Pacific, 110, 863-878.

Rodriguez, A., Arcay, B., Dafonte, C., Manteiga, M., & Carricajo, I. (2004). Automated knowledge-based analysis and classification of stellar spectra using fuzzy reasoning. Expert Systems with Applications, 27(2), 237-244.

Silva, D.R., & Cornell, M.E. (1992). Anew library of stellar optical spectra. The Astrophysical Journal Suppl, 81(2), 865-881.

Sowa, J.F. (1999). Knowledge representation: Logical and computational. Brooks Cole Publishing.

Stuttgart Neural Network Simulator. (2001). Retrievd from www-ra.informatik.uni-tuebingen.de/SNNS/

Valette-Florence, P. (1994). Introduction to means-end chain analysis. Rech. Appl. Mark, 9,93-117.

Weaber, W., & Torres-Dodgen, A. (1995). Neural networks classification of the near-infrared spectra of A-type Stars. The Astrophysical Journal, 446, 300-317.

Zombeck, M.V. (1990). Handbook of astronomy and astrophysics (2^{nd} ed.). Cambridge

University Press.

مَسْرد بالكلمات الصعبة

الدقة (Accuracy): خطأ القياس (أو التنبؤ)، الذي يكون قابلاً للتكرار من اختبار إلى اختبار. تُحدد الدقة بأخطاء نظامية (متكررة).

كمون الفعل (العمل) (Action Potential): إشارة كهربائية منتشرة لمسافات كبيرة بالخلايا القابلة للإثارة (على سبيل المثال، الخلايا العصبية والعضلية). وهي مُميّزة بعكس الكل أو لا شيء للكمون الغشائي، الذي يصبح في داخل الخلية موجباً بالنسبة للخارج، ولديه عتبة، ويتم إيصاله بدون تناقص. كما أنه يُعرف أيضاً كنبضة عصبية (سيالة عصبية).

تابع التفعيل (Activation Function): القيمة المتغيرة زمنياً، والتي هي خرج أي عصبون.

معدل التعلّم التكيّفي (Adaptive Learning Rate): هو معدل تعلّم، الذي يُضبط وفقاً لخوارزمية ما خلال التدريب لتقليل زمن التدريب إلى الحد الأدنى.

الخِلْط (Aggregate): هو مادة حشوة خاملة في الخرسانة، التي تسمح بخصائص فيزيائية جيدة بكلفة منخفضة.

Apoptosis: شكل موت الخلية المُبرمج والمُسبب بتنشيط الجزئيات الذاتية النشوء، والمؤدي إلى تجزؤ الـــ DNA.

البنية الهندسية (Architecture): وصف لعدد الطبقات في شبكة عصبونية صنعية،تابع التفعيل لكل عصبون، عدد العصبونات في الطبقة، والاتصالات بين الطبقات.

الذكاء الصنعي (Artificial Intelligence) (AI): يُعّرف الذكاء الصنعي غالباً بأنه ("قدرة حاسوب على أداء النشاطات، التي يُعتقد عادةً بأنها تتطلب ذكاءً). يُفّرع AI كعلم إلى عدة خطوط بحثية معتمدة على الطرق المستخدمة لتحقيق الذكاء متضمناً النظم الخبيرة، المنطق العائم، والشبكات العصبونية الصنعية.

الشبكات العصبونية الصنعية (Artificial Neural Network) (ANN): أي شبكة عصبونية صنعية هي نظام معالجة معلومات معتمد على تعميمات الإدراك البشري أو البيولوجية العصبية. وهي نماذج الكترونية أو حسابية معتمدة على البنية العصبونية للدماغ. يتعلم الدماغ بشكل أساسي من التجارب. هناك نوعان رئيسان لـــ ANN. يكون الأول فقط باتصالات أمامية

الانتشار ويدعى ANN أمامية الانتشار. أما الثاني فيكون باتصالات عشوائية بدون أي اتجاه وتدعى غالباً بـــ ANN التكرارية (RANN). يتضمن النوع الأكثر شيوعاً لـــ ANN على طبقات مختلفة مع بعض العصبونات في كل طبقة منها متصلة باتصالات أمامية الانتشار ومدربة بخوارزمية الانتشار الخلفي.

الخلية النجمية (خلية الدبق النجمية) (Astroglia) (Astrocyte): خلية نجمية الشكل وخصوصاً خلية الدبق العصبي للنسيج العصبي، التي تدعم الخلايا العصبية.

الارتباط الذاتي (Autocorrelation): أي إشارة مرتبطة مع نفسها. وهو مفيد لان تحويل فورييه للارتباط الذاتي هو طيف الطاقة للإشارة الأصلية.

الجهاز العصبي المستقل وظيفيا (Autonomic nervous system): جزء من الجهاز العصبي الفقاري، الذي ينظم العمل اللاإداري مثل الأمعاء، القلب، والغدد. وهو مُقسم إلى الجهاز العصبي الودي، والنظام العصبي قرب الودي.

المحوار (Axon): الناتئة الطويلة عادة لليف عصبي، التي توصل النبضات (السيالة) العصبية بعيداً عن جسم الخلية العصبية.

الانتشار الخلفي (قاعدة دلتا المُعممّة) (Genralised Delta-Rule) (Backpropagation): قاعدة تعلّم، تُضبط فيها الأوزان والانحيازات بأشعة أخطاء مشتقة (دلتا) منتشرة خلفاً عبر الشبكة. يطبق الانتشار الخلفي عموماً على الشبكات متعددة الطبقات أمامية الانتشار. تدعى هذه القاعدة أحياناً بقاعدة دلتا المُعممّة.

توابع الأساس (Basis Functions): مجموعة من الأشكال الموجية المستخدمة بفك التركيب. على سبيل المثال، التوابع الأساسية لفك تركيب فورييه هي موجات جيبية وتجيبية أُحادية المطال.

أطار عمل شبكة Bayes (Bayesian Framework): تفرض بأن الأوزان والانحيازات للشبكة هي متغيرات عشوائية بتوزيعات محددة.

الانحياز (Bias): بارامتر خلية عصبونية بمجموع مع الأوزان المُثقّلة للخلية العصبونية، ومُرّر عبر تابع نقل الخلية العصبونية لتوليد خرج الخلية العصبونية.

شعاع الانحياز (Bias vector): شعاع عمودي لقيم الانحياز لطبقة من العصبونات.

مانع دم الدماغ (Blood-Brain Barrier) (BBB): آلية فسيولوجية، تُعدّل نفاذية أوعية الدماغ الشعرية، بحيث تُمنع بعض المواد مثل مخدرات معينة من الولوج إلى نسيج الدماغ، في حين يُسمح لمواد أخرى الدخول بحرية.

الصك (Bond): مستند دين، الذي يسدد مبلغ مدوّن من الفائدة على أساس قانوني. يُعرف مبلغ الدين بالرئيس (رأسمال المال)، والتعويض المعطى للدائنين لجعل مثل هذه الاعتمادات المالية متوفرة هو نموذجياً في صيغة دفعات فائدة. توجد ثلاثة أنواع رئيسية للصُكوك: متعلق بالشركات، حكومية، وبلدية. يدعى الصك المتعلق بالشركات مع تخمين ائتمان منخفض بصك عالي المردود أو صك خردة.

تخمين الصكوك (Bond Rating): تقييم الاحتمالية بأن مصّدر الصك سيدفع الفائدة على دينه في الوقت المحدد. تُعيّن تخمينات الصكوك من قبل مكاتب (وكالات) مستقلة مثل وكالة خدمة المستثمرين Moody ووكالة Standard & Poor. تمتد التخمينات من AAA أو Aaa (الأعلى) إلى D (أثناء التخلف). تكون الصكوك المُخمنة أقل من B ذات درجة غير استثمارية، وتدعى بالصكوك العالية المردود أو صكوك الخردة. بما أن احتمالية التخلف تكون أكبر على مثل هذه الصكوك، فإن الإصدارات تُجبر لدفع أسعار فائدة أعلى لجذب المستثمرين.

جسم الخلية (Cell Body) (Soma): قسم من خلية عصبونية، يحتوي على النواة، لكنه لا يضم التغصنات أو المحوار.

الاسمنت (Cement): هو خليط مسحوق بشكل ممتاز، ومجفف في الفرن، من مواد الأرض الطبيعية والمُستخدم كجزء رابط في الخرسانة.

الجهاز العصبي المركزي (Central Nervous System): جزء من الجهاز العصبي الفقاري، يشمل الدماغ والنخاع الشوكي.

Cepstrum: إعادة تنظيم طيف. مُستخدم في معالجة متماثلة الشكل لوصف الطيف، عندما يكون مجال التردد ومجال الزمن محولّين.

الهندسة المدنية (Civil Engineering): مجال واسع من الهندسة الذي يتعامل مع تخطيط، بناء، وصيانة البنى الثابتة أو الأشغال العامة، عندما نتعلق بالأرض، الماء، أو الحضارة وعملياتها. تتعامل غالبية الهندسة المدنية الحالية مع الطرق، البنى، إمداد المياه، مجاري التصريف، السيطرة على الفيضان أو المرور.

التصنيف(Classification): ربط دخل بشعاع هدف معين.

العنقدة (Clustering): تجد خوارزميات العنقدة مجموعات الصنوف، التي تكون متشابهة. على سبيل المثال، قد تُستخدم العنقدة من قبل شركة تأمين لتجميع الزبائن وفقاً للدخل، العمر، نوع سندات التأمين المشتراة، وخبرة المطالب السابقة.وهي تقسم مجموعة من المعطيات، بحيث تكون التسجيلات بمضامين متماثلة في نفس المجموعة ومجموعات مختلفة بقدر الإمكان عن بعضها البعض. وبما أن الأصناف غير محددة، فإن هذا يُدعى أحياناً بتعلّم غير مُراقب.

طبقة تنافسية (Competitive Layer): طبقة عصبونات، التي يكون فيها فقط للخلية العصبونية بمدخلات شبكة عظمى خرج 1، ويكون لكافة العصبونات الأخرى خرجاً مساوياً للصفر. تتنافس العصبونات بين بعضها البعض من أجل حق الاستجابة لشعاع دخل معطى.

التعلم التنافسي (Competitive Learning): التعلم غير المُراقب لطبقة تنافسية بقاعدة Instar أو قاعدة KoHonen. تتعلّم العصبونات الفردية لتصبح كواشف سمات. بعد التدريب تُصنف الطبقة أشعة التدريب بين عصبوناتها.

تابع النقل التنافسي (Competitive Transfer Function): يقبل شعاع دخل شبكة لطبقة تنافسية، ويعيد مخرجات عصبونية صفرية لكافة العصبونات بالاستثناء العصبون الرابح، وهو العصبون المّرافق بالعنصر الأكثر إيجابيةً لدخل الشبكة n.

الخرسانة (Concrete): هو كتلة الرمل، الحصى، الصخر المسحوق، أو خلْط آخر المربوطة معاً بعجينة مُصلّبة لاسمنت هيدروليكي وماء.

خوارزمية التدرج المترافقة (Conjugate Gradient Alogrithm): يُنفذ في خوارزميات التدرج المترافقة بحث على طول الاتجاهات المترافقة، التي تُنتج تقارباً بشكل عام أسرع من بحث على طول الاتجاهات المنحدرة الحادة.

الاتصال (Connection): وصلة أحادية الاتجاه بين عصبونات شبكة ما.

وزن الاتصال (Connection weight): وزن وصلة بين عصبونين في شبكة ما. يحدد الوزن التأثير الذي يملكه عصبون آخر.

الاتصالية (Connectivity): مستوى الاتصال البيني في نظام ما، بنية الأوزان في شبكة عصبونية ما، أو العدد النسبي للحواف في مخطط ما.

القشرة (Cortex): الطبقة الخارجية للمادة الرمادية التي تغطي سطح كل نصف كرة مخية.

تخمين الائتمان (Credit rating): أي تخمين ائتمان هو تقييم من قبل طرف ثالث لاعتماد ائتمان مصدّر لكافلات مالية. وهو يخبر المستثمرين عن احتمالية التخلف، أو عدم التسديد، أو الالتزامات المالية للمصدّر.

التصالب (Crossover): العملية الوراثية، التي يتبادل فيها صبغيان متزاوجان قسماً أقصى من DNA خاصتهما.

عنقدة المعطيات (Data clustering): تقنية شائعة لتحليل المعطيات، التي تُستخدم في مجالات عديدة متضمنةً تعلّم الآلة، التنقيب في المعطيات، تمييز الأنماط، تحليل الصورة، المعلوماتية البيولوجية، ومحركات البحث.

التنقيب في المعطيات - اكتشاف المعرفة في قواعد المعطيات (Data mining - Knowledge discovery in database) (KDD):

هو فعالية استخلاص معلومات، هدفها اكتشاف الحقائق الخفية المحتواة في قواعد المعطيات. باستخدام توليفة من تعلّم الآلة، التحليل الإحصائي، تقنيات النمذجة، وتكنولوجية قاعدة المعطيات يجد التنقيب في المعطيات الأنماط والعلاقات بين المعطيات، ويستنتج القواعد التي تسمح بتنبؤ النتائج المستقبلية. تتضمن التطبيقات النموذجية تجزؤ السوق، تشخيص الزبون، كشف الاحتيال، تقييم ترويج البيع بالتجزئة، وتحليل مخاطرة الائتمان.

حد القرار (Decision boundary): خط مُحدّد بالأوزان وشعاع الانحياز، ويكون صفراً من أجل دخل صافي n.

فك التركيب (Decomposition): عملية فصل الإشارة إلى مركبتين مضافتين أو أكثر. وغالباً ما يُشار بشكل خاص إلى تحويل فورييه الأمامي، الذي يفصل أي إشارة إلى منحنيات جيبية.

شعاع الدلتا (Delta vector): شعاع الدلتا لطبقة ANN هو مشتق خطأ خرج الشبكة بالنسبة لشعاع الدخل الصافي لتلك الطبقة.

التغصّن (Dendrite): ليف قصير، يوصل المعلومات باتجاه جسم خلية العصبون.

تابع المسافة (Distance function): أسلوب خاص لحساب المسافة، مثل المسافة الأقليدية بين شعاعين.

الحقبة (الدورة) (Epoch): تقديم مجموعة أشعة التدريب (دخل و/أو خرج) إلى ANN، وحساب الأوزان والانحيازات الجديدة. لاحظ أن أشعة التدريب يمكن أن تقدّم كلٌ على انفراد أو سويةً في دفعة واحدة.

نسبة الخطأ (Error ratio): بارامتر تدريب مستخدم مع معدل التعلّم التكيّفي وتدريب الزخم للشبكات ANNs خلفية الانتشار.

شعاع الخطأ (Error vector): الفرق بين شعاع خرج ANN في الاستجابة لشعاع دخل وبين شعاع خرج الهدف المُرافق.

الحوسبة التطورية (EC) (Evolutionary Computation): تحيط بطرق محاكاة التطور على حاسوب. يمثل المصطلح الجهد الذي يجلبه الباحثون معاً العاملون في الحقول الوثيقة الصلة، ولكن يتبعون مخططات مختلفة.

النظم الخبيرة (Expert Systems): فرع من الذكاء الصنعي. تستخدم النظم الخبيرة تدرجاً معقداً من القواعد لإنجاز "مهام ذكية" معتمدة على المعطيات المتاحة. تتضمن الأمثلة تشخيص الأمراض والتحليل المالي.

سلبي كاذب (False Negative): إحدى النتائج المحتملة الأربعة لمحاولة كشف هدف. الهدف موجود، ولكن يُشار إليه بشكل خاطئ بأنه غير موجود.

إيجابي كاذب (False Positive): إحدى النتائج المحتملة الأربعة لمحاولة كشف هدف. الهدف غير موجود، ولكن يُشار إليه بشكل خاطئ بأنه موجود.

شبكة ذات تغذية عكسية (Feedback Network): ANN باتصالات من خرج طبقة ما إلى دخل تلك الطبقة. يمكن أن يكون اتصال التغذية العكسية مباشراً أو بعبور عدة طبقات.

شبكة أمامية الانتشار (Feedforward Network): ANN ذات طبقات، التي تستقبل فيها كل طبقة المدخلات فقط من الطبقات السابقة.

التنبؤ (Forecasting): القيام بالتوقعات حول الأداء المستقبلي على أساس معطيات الظروف الحالية والتاريخية (القديمة).

التقريب الوظيفي (Function Approximation): المهمة المُنجزة بواسطة ANN مُدربة للاستجابة لمدخلات بتقريب وظيفة مرغوبة.

المنطق العائم أو الغامض (Fuzzy Logic): فرع الذكاء الصنعي. بينما تستخدم غالبية الأنظمة الحاسوبية منطق بول حيث كل شيء مُشكل بـــ 1 أو 0، صحيح أو خاطئ، يستخدم المنطق العائم "الحقيقة الجزئية". وهذا يساعد في التعامل مع بعض المفاهيم البشرية كمعنى اللغة الطبيعية (هذا يعني بالتأكيد 84% X)، والقياس (أي شخص الذي يكون طوله 190سم هو بالتأكيد 70% طويل، وأي شخص طوله 210 سم يكون بكافة الإجراءات بالتأكيد 100% طويل).

التعميم (Generalization): مقياس لكيف يمكن لـــ ANN الاستجابة بشكل جيد لمعلومات دخل جديدة، التي لم تُدرب عليها، ولكنها تكون متعلقة بطريقة ما بأنماط التدريب. إن قدرة التعميم حاسمة لإمكانية اتخاذ القرار لـــ ANN. وهو خاصية ANN، التي يميل خرجها من أجل شعاع دخل جديد ليكون قريباً من مخرجاتها من أجل أشعة دخل مشابهة في مجموعة تدريبها.

الخوارزمية الوراثية (GA) (Genetic Algorithm): خوارزمية مستخدمة لإيجاد حلول تقريبية للمسائل صعبة الحل عبر تطبيق مبادئ البيولوجية التطورية على علم الحاسوب.

البرمجة الوراثية (GP) (Genetic Programming): نوع من البرمجة، تستخدم نفس خصائص الاصطفاء الطبيعي الموجودة في التطور البيولوجي. الفكرة العامة وراء البرمجة الوراثية هي البدء بمجموعات من الوظائف ودمجها عشوائياً في برامج. ثم تُشغّل البرامج، ويلاحظ أي منها يعطي النتائج الأفضل، يتم الاحتفاظ بالبرامج الأفضل (الاصطفاء الطبيعي)، ويُبدّل بعض الأخرى، ثم يُختبر التوليد الجديد. تُكرر هذه العملية حتى ظهور برنامج أفضل بوضوح.

الغدة (Gland): العضو، الذي ينتج إفرازاً لاستخدامه في مكان ما في الجسم، أو في تجويف الجسم، أو لكي يُزال من قبل الجسم.

الدبق (Glia): نسيج داعم، يحيط ويدعم العصبونات في الجهاز العصبي المركزي. تُشكل الخلايا العصبية والدبقية معاً نسيج الجهاز العصبي المركزي، كما أن الخلايا الدبقية المسماة الدبق العصبي لا توصل النبضات (السيالة) الكهربائية على خلاف العصبونات.

النهاية الصغرى العامة (Global Minimum): القيمة الأدنى لتابع على كامل مجال بارامترات دخله. تضبط طرق الهبوط المتدرج الأوزان والانحيازات بغية إيجاد النهاية الصغرى العامة للخطأ من أجل ANN.

الهبوط المتدرج (Gradient Descent): عملية تشكيل التغييرات في الأوزان والانحيازات، حيث تكون التغيرات متناسبة مع مشتقات خطأ الــ ANN بالنسبة لتلك الأوزان والانحيازات. ويُنفذ ذلك من أجل تقليل خطأ الــ ANN إلى الحد الأدنى.

قاعدة تعلم هيب (Hebb) (Hebb Learning Rule): تاريخياً، هي أول قاعدة تعلّم مقترحة للعصبونات. تُضبط الأوزان طرداً مع جداء مخرجات العصبونات قبل التثقيل وبعد التثقيل.

تعلّم هيب (Hebb) (Hebbian Learning): عملية الشبكات ANNs التي تقوي الاتحاد بين عصبونين نشيطين بشكل آني.

الطبقة الخفية (Hidden Layer): طبقة من ANN، ليست دخلاً ولا خرجاً لــ ANN.

Hopfield ANN: مثال خاص لــ ANN قادرة على تخزين واسترداد الذاكرات أو الأنماط. ترسل كافة العقد في الــ ANN الإشارات إلى كافة العقد الأخرى.

علم المياه (hydrology): هو دراسة حدوث توزيع وحركة المياه على الأرض، وفيها، وفوقها.

جهاز المناعة (Immune System): جهاز الجسم المتكامل من الأعضاء، الأنسجة، الخلايا، ومنتجات الخلايا كالأجسام المضادة التي تميز الذاتي عن غير الذاتي، وتُبطل بالفعل عمل الكائنات الحية المجهرية، أو المواد المسببة للمرض.

التهيئة (Initialization): عملية إعادة وضع أوزان وانحيازات الشبكة إلى قيمهم الأصلية.

طبقة الدخل (Input Layer): طبقة العصبونات، التي تستقبل المدخلات مباشرةً من خارج الـ ANN.

طبقة الدخل (Input Space): مجال كافة أشعة الدخل الممكنة.

شعاع الدخل (Input Vector): شعاع المدخلات المُقدم لـ ANN.

أوزان الدخل (Input Weights): الأوزان، التي تُوصل مدخلات ANN إلى طبقة الدخل.

نظام كشف التدخل (IDS) (Intrusion Detection System): أداة برمجية مستخدمة لكشف الولوج غير المخوّل إلى نظام حاسوب أو شبكة. قد يأخذ ذلك شكل هجمات من قبل لصوص الحاسوب الخبثاء الماهرين باستخدام أدوات مؤتمتة.

قاعدة تعلّم KoHonen (Kohonen Learning Rule): قاعدة تعلّم، تدرّب أشعة أوزان العصبون المختار لأخذ قيم شعاع الدخل الحالي في شبكة KoHonen ANN.

الطبقة (Layer): مجموعة من العصبونات، تمتلك تابعاً معيناً، وتُعالج كوحدة كاملة. المثال الأكثر شيوعاً هو في ANN أمامية الانتشار، والتي تمتلك طبقة دخل، طبقة خرج، وطبقة خفية واحدة أو أكثر.

مخطط الطبقة (Layer Diagram): شكل البنية الهندسية لـ ANN، الذي يظهر الطبقات ومصفوفات الأوزان التي تصل بينهم. كل تابع نقل طبقة مُشار إليه برمز. وتكون أحجام الدخل، الخرج، الانحياز، ومصفوفات الأوزان مبينة، ولا يتم إظهار العصبونات الفردية والاتصالات.

أوزان الطبقة (Layer Weights): هي الأوزان، التي تصل الطبقات بطبقات أخرى. تحتاج مثل هذه الأوزان أن يكون لديها تأخيرات لا صفرية، إذا كانوا يشكلون اتصالاً تكرارياً.

خوارزميات التعلّم (مُراقب، غير مُراقب) (Unsupervised ،Supervised) Learning Algorithms):
أي عملية تكيّف، تُعدّل آلياً المشابك، أوزان الـ ANNs، شدات المُصنفيّن أو مجموعة أخرى من البارامترات القابلة للتعديل، بحيث يُنجز هدف ما بسهولة أكثر. خوارزميات الانتشار الخلفي واللواء المندفع هما نوعين من عمليات التعلّم.

معدل التعلّم (Learning Rate): بارامتر تدريب، يتحكم بحجم تغيرات الأوزان والانحيازات خلال عملية تدريب ANN.

قاعدة التعلّم (Learning Rule): الخوارزمية المستخدمة لتعديل أوزان الاتصال في استجابة لأنماط التدريب، بينما تُنفذ عملية التدريب.

النهاية الصغرى المحلية (Local Minimum): النهاية الصغرى لتابع على مجال محدود من قيم الدخل. قد لا تكون أي نهاية صغرى محلية هي النهاية الصغرى العامة.

تابع الخطأ التربيعي المتوسط (Mean squared Error (MSE) Function) (MSE): تابع الأداء الذي يحسب الخطأ التربيعي المتوسط بين مخرجات ANN والمخرجات الهدف.

نظام MK (MK System): نظام التصنيف القياسي. طُوّر نظام الباحثين Morgan وKeenan (MK) في الأربعينات من القرن العشرين (1940s)، وبسبب استخدام الفلم الفوتوغرافي، فقد اعتمد النظام على مجال صغير في القسم الأزرق للطيف النجمي من أجل التصنيف. خلال السنوات العشرين الماضية، اعتمد الفلكيون على الكواشف الالكترونية، التي هي أكثر حساسية في المجالات الحمراء من الطيف.

الزخم (Momentum): تقنية مستخدمة غالباً لجعل حصول ANN خلفية الانتشار على نهايات صغرى ضحلة أقل احتمالاً.

ثابت الزخم (Momentum Constant): بارامتر تدريب الذي يتحكم بكمية الزخم المُستخدم.

شبكة Perceptron متعدد الطبقات (Multi-Layer Pereptron) (MLP): نوع من ANN أمامية الانتشار، الذي هو امتداد لشبكة Perceptron من حيث أنها تمتلك على الأقل طبقة خفية واحدة من العصبونات. تُحدّد الطبقات بالبدء بالمدخلات والنهاية بالمخرجات يحسب كل عصبون المجموع المُثقل للإشارات الواردة ليعطي خرجاً صافياً، وتُمرر هذه القيمة عبر تابع تفعيله السيغمويدي لإنتاج قيمة تفعيل العصبون. بخلاف شبكة Perceptron، يمكن لـ MLP أن تحل مسائل متلازمة خطياً.

الطفرة (Mutation): المعامل الوراثي، الذي يقوم بتغيير مورثة صبغي ما لكائن ما مؤدياً إلى سلسلة فردية جديدة غير موجودة في النمط الأبوي.

الاصطفاء الطبيعي(Natural Selection): عملية في الطبيعة التي فيها، طبقاً لنظرية داروين للتطوير، تميل فقط الكائنات الحية الأكثر تكيّفاً لبيئتهم إلى البقاء، وإرسال خصائصهم الوراثية في أعداد متزايدة للأجيال التالية، بينما تميل تلك الكائنات الحية الأقل تكيّفاً إلى أن تكون مُزالة.

الجوار (Neighborhood): مجموعة من العصبونات ضمن مسافة محددة من عصبون معين.

الجهاز العصبي (Nervous System): نظام التنسيق المُتخصّص للخلايا، الأنسجة، والأعضاء الذي يهب الحيوانات الإحساس والإرادة. في الفقاريات، يكون الجهاز العصبي غالباً مقسماً إلى جهازين: المركزي (الدماغ والنخاع الشوكي)، والمحيطي (الجهاز العصبي الجسدي والمستقل).

الدبق العصبي (Neuroglia): شبكة من الخلايا والألياف المتفرعة، التي تدعم نسيج الجهاز العصبي المركزي. كما يُدعى أيضاً بالدبق.

العصبون (Neuron): وحدة حسابية بسيطة، تقوم بجمع مُثقل للإشارات الواردة، وتصنيف حد عتبة أو انحياز لهذه القيمة لإنتاج دخل صافي. وتُنقل القيمة الأخيرة عبر تابع تفعيلها لحساب تفعيلها الخاص. ستحتفظ بعض العصبونات، كتلك الموجودة في الشبكات ذات التغذية العكسية وHopfield، بقسم من تفعيلهم السابق.

النواقل العصبية (Neurotransmitters): مجموعة من المواد التي تُحرّر بالإثارة من طرف المحوار لعصبون قبل مشبكي للجهاز العصبي المركزي أو المحيطي، وتُنقل عبر الشق المشبكي إلى خلية الهدف أخرى مثارة أو مثبطة. من بين العديد من المواد، التي تمتلك خصائص الناقل العصبي نذكر: اسيتيلكولاين (acetylcholine)، نورادينالين (noradrenaline)، أدرينالين (adrenaline)، دوبامين (dopamine)، غلوسين (glycine)، حمض كلوتاميك (glutmic acid)، اينكيفا لينـــز (enkephalins)، ايندورفيتز (endorphins)، وسيروتونين (serotonin).

الكائن الحي (متعضٍ) (Organism): شكل فردي من الحياة مثل نبات، حيوان، بكتريا، أو الفطر. أي، جسم مكّون من أعضاء الخلية، أو أجزاء أخرى، التي تعمل سويةً لمواصلة العمليات المختلفة للحياة.

طبقة الخرج (Output Layer): الطبقة التي يُمرّر خرجها إلى الوسط الخارجي لـــ ANN.

شعاع الخرج (Output Vector): خرج أي ANN. كل عنصر من شعاع الخرج هو الخرج لعصبون ما.

قاعدة التعلّم Outstar (Outstar Learning Rule): قاعدة تعلّم، تدرب شعاع وزن خرج عصبون لتأخذ قيم شعاع الخرج الحالي لطبقة الوزن السابقة. تتناسب التغيرات في الأوزان طرداً مع خرج العصبون.

الإفراط في التدريب (Overfitting): حالة، يكون فيها الخطأ على مجموعة التدريب، مُقاداً إلى قيمة صغيرة جداً، ولكن عندما تُقدم معطيات جديدة لـــ ANN يصبح الخطأ كبيراً.

باثولوجيا (علم الأمراض) (pathology): دراسة طبيعية المرض وأسبابه، العمليات، التطورات والنتائج، ودراسة التوضيح التشريحي أو الوظيفي لمرض ما.

ربط الأنماط (Pattern Association): المهمة المُنفذة من قبل أي ANN مدربة للاستجابة بالشعاع الخرج الصحيح لكل شعاع دخل مقدم.

تمييز الأنماط (Pattern Recognition): المهمة المنفذة من قبل ANN مدربة للاستجابة عندما يُقدم شعاع دخل قريب من شعاع مُعلّم. تمييز الشبكة المُدخل كأحد أشعة الهدف الأصلية. ويمكن أن يُنفذ ذلك بالـــ ANN حتى في وجود ضجيج أو عندما تكون بعض المعطيات مفقودة.

شبكة Perceptron (Perceptron): هي ANN قادرة على مهمات التصنيف وتمييز الأنماط البسيطة. وهي مركبة من طبقتين، حيث تُمرر الإشارات فقط إلى الأمام من عقد في طبقة الدخل إلى عقد في طبقة الخرج. ولا توجد أية اتصالات ضمن أي طبقة. تُدرب هذه الشبكة غالباً بقاعدة تعلّم Perceptron.

قاعدة تعلّم Perceptron (Perceptron Learning Rule): هي قاعدة تعلّم لتدريب ANN محدودة بشدة بطبقة واحدة. وهي تضمن إنتاج ANN، التي تقوم بالأداء الوظيفي على نحو تام في الوقت المُحدد، بفرض أن ANN قادرة على فعل ذلك.

الأداء (Performance): سلوك أي ANN.

تابع الأداء (Performance Function): بشكل عام، هو الخطأ التربيعي المتوسط (MSE) لمخرجات ANN.

المَظهَر الموروث (Phenotype): تعبير فيزيائي أو كيميائي حيوي للنمط الوراثي للسلاسل الفردية، وهي ميزات مُعبر عنها بشكل جدير بالملاحظة مثل لون العين والجلد.

التعلم التاريخي لتطور السلالة (Phylogenetic Learning): عملية التعلم، التي تحدث خلال ملايين السنين، حيث يُحكم تطور النوع بالاصطفاء الطبيعي. وهي هنا، أن تلك القدرات لإدراك السمات الأكثر أهمية للعالم حولنا – في مقاييس للحجم والزمن – والبقاء فيها، تكون مختارة بشكل مثالي.

الفسيولوجية (Physiology): دراسة وظائف الكائنات الحية وأجزائها.

درجة النغم (Pitch): الإدراك الحسي للتردد الأساسي لنغمة مستمرة.

تحليل المكونات الأساسية (Principal Component Analysis) (PCA): تعامد المكونات لأشعة دخل ANN. يمكن أن يخفض هذا الإجراء أيضاً حجم أشعة الدخل بإزالة المكونات الفائضة (الزائدة عن الحاجة).

شبكة الأساس الشعاعي (Radial Basis Network): وهي ANN، التي يمكن أن تُصمم بشكل مباشر بملاءمة عناصر استجابة خاصة، حيث ستقوم بالعمل الأفضل.

مستقبل (receptor): جزيئة خلية سطحية، تُربط بشكل محدد إلى بروتينات معينة أو هُضْميدات.

الانتشار الخلفي المرن (Resilient Backpropagation): خوارزمية تدريب، تزيل التأثير الضار لامتلاك منحدر صغير في النهايات القصوى لتوابع النقل السيغمويدية (الساحقة).

مَبحث الانسياب (يشمل المرونة واللزوجة واللدّونة)/سلوك المَبْحثي الانسيابي (Rheololgy/Rheological Behaviour): وهو علم تشوه وانسياب المادة، والتأكيد على معنى الانسياب الذي يهتم بالعلاقات بين الإجهاد، الجهد، معدل الجهد، والزمن.

نظرية المجموعات الخشنة (RST) (Rough Set Theory): يمكن أن يُقترب منها كامتداد لنظرية المجموعات الكلاسيكية للاستخدام عند تمثيل معرفة ناقصة. يمكن أن تُعتبر المجموعات الخشنة مجموعات ذات مجموعات الحدود العائمة، التي لا يمكن أن تُميّز بدقة باستخدام المجموعة المتاحة من الخواص.

خوارزمية التدرج المترافق المقيسة (Scaled Conjugate Gradient Algorithm): يتفادى البحث الخطي المستهلك للزمن خوارزمية التدرج المترافق القياسية من أجل عملية التدريب لـــ ANN.

التنظيم الذاتي (Self-Organizing): تدعى أي ANN تنظيماً ذاتياً، إذا كانت قادرة على تغيير اتصالاتها لكي تنتج استجابات مفيدة من أجل أنماط دخل بدون أي تعليمة من معلّم بارع.

تابع السيغمويد (Sigmoid Function): التابع الذي، يُستخدم غالباً كتابع تفعيل في الـــ ANN.

اختبار الكزازة (Slump Test): اختبار الكزازة هو طريقة الاختبار المشهورة والأكثر استعمالاً لتمييز إمكانية التشغيل لخرسانة طرية. يشمل الجهاز علي قالب في شكل مخروط ناقص. يُملئ القالب بالخرسانة، ثم يُرفع قالب مخروط الكزازة عمودياً إلى الأعلى، ويُقاس التغيير في ارتفاع الخرسانة.

الجسم (Soma): جسم الخلية العصبية، الذي يحتوي على النواة.

التحليل الطيفي (Spectral Analysis): في علم الفلك، هو دراسة تركيبات وبنية الأجسام بواسطة المطيافيّة.

الطيف (Spectrum): هو مخطط أو رسم بياني للشدة مقابل الطول الموجي أو التردد.

ثابت الانتشار (Spread Constant): المسافة لشعاع دخل، التي يجب أن تكون من شعاع وزن عصبون لإنتاج خرج مقداره 0.5.

الخلية السلالية (Stem Cell): الخلية، التي تسبب نَسَبْ الخلايا، وتستخدم بشكل خاص الوصف الخلايا الأكثر بدائيةً في نخاع العظم، الذي تُشتق منه كافة الأنواع المختلفة لخلايا الدم.

المُحفّز (Stimulus): أي معامل، يمكن أن يُكتشف بواسطة مستقبلٍ ما، والذي ينتج بدوره استجابة ما.

الخطأ التربيعي المتوسط (Sum-Squared Error): هو مجموع مربعات الفروق بين مَخْرجات الهدف لــ ANN والمخرجات الفعلية من أجل شعاع دخل معطى أو مجموعة من الأشعة.

تعلّم مُراقب (Supervised Learning): أي عملية تعلّم، تكون فيها التغيرات في أوزان وانحيازات الـــ ANN ناتجة عن تدخل أي معلّم خارجي. يزود المعلم أهداف الخرج نموذجياً.

المشبك (Synapse): الفضاء، الذي تمر فيه إشارة من عصبون آخر.

شعاع الهدف (Target Vector): شعاع الخرج المرغوب من أجل شعاع دخل معطى.

أشعة الاختبار (Test Vectors): مجموعة من أشعة الدخل (غير المستخدمة مباشرةً في التدريب)، التي تُستخدم لاختبار الـــ ANN المدربة.

العتبة (Threshold): أي كمية مضافة إلى (أو مطروحة من) المجموع المُثّقل للمدخلات إلى عصبون، والتي تشكل دخل العصبون الصافي. حدسياً، يكون الدخل الصافي (أو الانحياز) متناسباً مع الكمية، التي يجب أن تتجاوز التفعيلات العصبونية الواردة بغية تفعيل عصبون ما.

طابع الصوت (Timbre): الإدراك الحسي الإنساني للتوافقيات في الصوت.

سلسلة زمنية (Time Series): أي سلسلة قياسات مأخوذة عند نقاط متتالية بمرور الزمن. ينتج التنقيب في المعطيات، الذي يعالج السلاسل الزمنية، معاملات متعلقة زمنياً مدمجة مثل متوسط متحرك.

نسيج (Tissue): تنظيم الخلايا المتميزة لنوع مماثل. يوجد أربعة أنواع أساسية للنسيج: العضلي، العصبي، الجلدي (البشرة)، والرابطي.

توابع الطبولوجية (Topology Functions): طرق لترتيب العصبونات في طبولوجية شبكية، صندوقية، سداسية أو عشوائية.

التدريب (Training): إجراء حيث تُضبط ANN للقيام بعمل معين. ويُنظر إليه بشكل عام كعمل "غير فوري" بعكس الضبط المُنجز أثناء كل فترة زمن، كما يُنفذ في التدريب التكيفيّ.

مجموعة التدريب (Training Set): تُدرّب أي ANN باستخدام مجموعة تدريب. تشمل أي مجموعة تدريب على معلومات حول المسألة، التي ستُحل، كدخل.

شعاع التدريب (Training Vector): أي شعاع دخل و/أو هدف مستخدم لتدريب ANN.

السمة (Trait): خاصية أو شرط محدد جينياً (وراثياً).

المرحلة الرنانة (tuning Phase): دور تدريب خرائط ميزة التنظيم الذاتية (SOFM)، والذي خلاله يتوقع للأوزان الانتشار نسبياً بانتظام على فضاء الدخل، بينما يحتفظ بتشكيلة طبولوجيتها، التي تم إيجادها خلال مرحلة التشكيل.

تعلم غير مُراقب (Unsupervised Learning): عملية تعلّم، لا تكون فيها التغيرات في أوزان وانحيازات ANN ناتجة عن تدخل أي معلم خارجي. وبشكل عام، التغيرات هي تابع لأشعة دخل ANN الحالية، وأشعة الخرج، والأوزان، والانحيازات السابقة.

التحديث (Update): إجراء تغير ما في الأوزان والانحيازات. يمكن أن يحدث التحديث بعد تقديم شعاع دخل وحيد، أو بعد تجميع التغيرات على عدة أشعة دخل.

أشعة إثبات الصلاحية (Validation Vectors): أي مجموعة من أشعة الدخل (غير المستخدمة مباشرة في التدريب)، التي تُستخدم لمراقبة تقديم التدريب، لكي تمنع الـــ ANN من الإفراط في التدريب.

جهوري (Voiced): صوت الكلام الإنساني، الذي ينشأ كنبضات الهواء التي تعبر الحبال الصوتية. أحرف العلة هي مثال على الأصوات الجهورية.

الوزن (Weight): في أي ANN، هو الشدة لمشبك (أو اتصال) بين عصبونين. قد تكون الأوزان موجبة (استثارية) أو سلبية (تثبيطية). تُعتبر أيضاً العتبات لعصبون ما أوزاناً، بما أنهم يخضعوا للتكيّف من قبل أي خوارزمية تعلّم.

تابع الوزن (Weight Function): تطبق توابع الوزن الأوزان على أي دخل للحصول على مُدْخلات مُثقّلة كما هو مُحدد بتابع معين.

مصفوفة الأوزان (Weight matrix): أي مصفوفة تحتوي على أوزان الاتصال من مُدْخلات طبقة ما إلى عصبوناتها. يشير العنصر W_{ij} من مصفوفة أوزان W إلى شدة الاتصال من العصبون j إلى العصبون i.

شعاع دخل مُثقّل (Weighted Input Vector): نتيجة تطبيق وزن ما إلى دخل طبقة ما سواءً أكان ذلك دخل ANN، أو الخرج لطبقة أخرى.

إمكانية التشغيل (Workability): تعّرف ACI إمكانية التشغيل بأنها" تلك الخاصية للخرسانة الممزوجة حديثاً، التي تحدد السهولة والتجانس، التي يمكن بها أن تُخلْط، تُوضع، تُحمّد وتُنهى". إن إمكانية التشغيل تتأثر بكل مكون من الخرسانة، وجوهرياً بكل شرط تُصنع وفقه الخرسانة. وتتضمن قائمة من المعاملات: الخصائص وكمية الاسمنت، التمهيد (التسوية)، الشكل، التزّوي، القوام السطحي للخلْطات الخشنة والناعمة، نسبة الركام، كمية الهواء التي تم جرها، نوع وكمية البزولان (تراب بركاني)، أنواع وكمية المزج الكيميائي، درجة حرارة الخرسانة، طريقة وزمن المزج، والزمن من لحظة تلامس الماء والاسمنت.

جدول المحتويات

المقدمة 5

القسم الأول: التعديل البيولوجي (الحيوي) 9

1 سلوك الدبق العصبي في علم الحاسوب 11

ملخص 11
مقدمة 11
علم الأعصاب والأنظمة الربطية 12
الخلايا النجمية: وظائف في معالجة المعلومات 13
الاتصال بين الخلايا النجمية، والخلايا العصبة: مفهوم جديد للمشبك 15
السوابق 18
مقدمة 18
الشبكات العصبونية الصنعية 18
أنوع ANN المختلفة 20
بعض القيود المرصودة 21
شبكات الدبق العصبونية الصنعية 22
مقدمة 22
تحليل النماذج والفرضيات على الخلايا النجمية 23
الأحداث المخية المدروسة 24
احتمالات تأثير العناصر والظواهر المخية على CS 25
اقتراح الأداء الوظيفي لـ ANGN 27
طور التصميم 27
طور التدريب 28
طور الاختبار التنفيذ 29
مقارنة بين طريقة التعلّم المقترحة والطرق الموجودة 29
التطويرات المستقبلية 31
المراجع 32

2 الخلايا النجمية والشبكات العصبونية الحيوية 35

ملخص 35
مقدمة 35
الشبكات العصبونية الحيوية 37
البنية الهندسية ووظيفة الخلية العصبية 38
الفسيولوجية المشبكية 40
شبكات الدبق العصبوني 43
دعم الخلايا النجمية ومراقبة النشاط العصبوني 44
الاتصال الخلوي البيني لخلية نجمية 46
الاتصال خلية عصبية - خلية نجمية 48
الاتجاهات المستقبلية 52
الاستنتاجات 54
المراجع 56

القسم الثاني: تنبؤ السلاسل الزمنية 63

3 تنبؤ السلاسل الزمنية بالشبكات العصبونية التطويرية 65

ملخص 65
مقدمة 65
خلفية 67
تحليل السلاسل الزمنية 67
الشبكات العصبونية الصنعية في تنبؤ السلاسل الزمنية 70
بيانات السلاسل الزمنية 71
الطريقة التجريبية لاختيار النموذج 73
طريقة تطويرية لاختيار النموذج 77
المناقشة 82
الاتجاهات المستقبلية 87
الاستنتاجات 88
المراجع 90

4 تطوير الشبكات العصبونية الصنعية بالاتصالات التكيفية بواسطة الحوسبة التطويرية........ 93
ملخص........ 93
مقدمة........ 93
الاقتراح........ 96
تطوير متعدد المستويات لـ ANNs مع تفعيل زمني موهن........ 96
أتمتة التطوير الطبولوجي........ 96
تشكيل GA........ 98
تدريب ANN بواسطة GA........ 101
معامل التصالب........ 103
إضافة ميزات بيولوجية........ 104
العصبون الطبيعي........ 104
البنية الهندسية مع تفعيل موهن زمنياً........ 105
الحصول على ميول التفعيل........ 107
النتائج........ 107
التفعيلات الموهنة زمنياً........ 109
الحصول على البنية الهندسية المثالية........ 110
الخلاصات........ 114
المراجع........ 115

القسم الثالث: التنقيب عن البيانات........ 117

5 الأنظمة العصبونية الذكية ذاتية التكيّف باستخدام تقنيات تطورية........ 119
ملخص........ 119
مقدمة........ 119
النظام التطوري لبناء الشبكات........ 121
تصميم شبكات عصبونية بالخوارزميات الوراثية........ 122
تابع التقييم........ 123
طرق تصنيف البنى الهندسية العصبونية........ 124
معاملات التصالب الثنائية........ 128
تدريب الشبكات العصبونية بخوارزميات وراثية........ 130

النظام التطوري لتصميم وتدريب الشبكات العصبونية 134
تطبيق: تشخيص سرطان الثدي 137
الاتجاهات المستقبلية 139
الخلاصة 140
المراجع 141

6 استخدام البرمجة الوراثية لاستخلاص المعرفة من الشبكات العصبونية الصنعية 143

ملخص 143
مقدمة 143
البرمجة الوراثية 144
استخلاص قواعد ANN 145
أنظمة استخلاص المعرفة 147
مقدمات تطويرية 147
وصف النظام 148
اكتشاف قدرة التعميم 149
استخلاص القواعد بـ RANN للتنبؤ بالسلاسل الزمنية 155
أمثلة القواعد المكتسبة 156
تشكيل بارامتر GP 157
النتائج 158
ينصح بالانتشار الأمامي للتصنيف 158
تنبؤ السلاسل الزمنية 159
الاستنتاجات 165
الدراسات المستقبلة 166
المراجع 167

7 عدة طرق لاختيار المتغيرات بواسطة الخوارزميات الوراثية 171

ملخص 171
مقدمة 171
اختيار المتغيرات 172

الحوسبة التطورية 172
الأساسيات البيولوجية 173
العملية الأساسية للخوارزمية التطورية 173
تقنيات الحوسبة التطورية لاختيار المتغيرات 174
البحث المُشذب 174
البحث الثابت 176
بحث متعدد الشكلية 176
تطبيقات عملية: اختيار المتغيرات الطيفية للأشعة تحت حمراء (IR) لتصنيف مشروبات التفاح ... 181
تقييم الحل 183
النتائج والمناقشة 187
الاستنتاجات 193
المراجع 195

القسم الرابع: الهندسة المدنية 197

8 نظام هجين من الشبكات العصبونية الصنعية والحوسبة التطورية في الهندسة المدنية 199

ملخص 199
مقدمة 199
خلفية 200
وصف المسألة 200
الشبكات العصبونية الصنعية 201
البرمجة الوراثية 203
الطرق الهيدروليكية 203
المخططات المائية الوَحْدِيّة 203
المعادلات الهيدروليكية 205
النماذج المعتمدة على بيانات حقيقية 205
النمذجة 206
نمذجة معدل التدفق اليومي بواسطة ANN 207
نمذجة تدفق المطر 210
نمذجة تدفق المطر بتابع انحدار خطي 212

نمذجة تدفق المطر بواسطة RANN 213
نمذجة تدفق المطر بالبرمجة الوراثية 213
نمذجة تدفق المطر بمِخطاط مائي وُحْدّي SCS 216
استجابات المِخطاط المائي الوَحْديّ بالطرق 216
النتائج 216
وصف النظام 218
الاتجاهات المستقبلية 219
الاستنتاجات 219
المراجع 220

9 التنبؤ بالتماسكية الخرسانية بواسطة استخدام الشبكات العصبونية الصنعية 223

ملخص 223
مقدمة 223
الانسياب الخرساني وقابلية لتشكيل 223
قياس إمكانية التشكيل للخرسانة 224
العوامل التي تأثر على قابلية التشكيل 226
بناء ANN 227
المعطيات الابتدائية 227
التساؤلات المسبقة حول البنية الهندسية لـ ANN 229
التدريب باستخدام خوارزميات وراثية 230
تشكيل الـ ANN النهائية 231
تحليل النتائج 231
الاستنتاجات 233
المراجع 235

القسم الخامس: التحليل المالي 237

10 طريقة الحساب الناعم لتوقع تخمين (تسعير) الصكوك 239

ملخص 239
مقدمة 239

فحص المادة المطبوعة حول هذا الموضوع 241
الطرق الإحصائية لتخمين الصكوك 242
صياغة المسألة........ 243
شبكات Kohonen........ 244
FCM 245
شبكة عنقدة Kohonen العائمة (FKCN) 247
منهجية الحل........ 249
اختيار الدخل........ 249
المعالجة المسبقة........ 249
تخفيض البُعدية 249
مصفوفات الأداء........ 249
الوضعية التجريبية 250
مصادر البيانات........ 250
مجموعات البيانات المستخدمة 251
الطرق........ 251
تقنية تخفيض البُعدية 251
تقنية المتغير المُخفض........ 252
منهجية الحل النسبي (المقارن)........ 252
النتائج والتحليل........ 253
تقنية تخفيض البُعدية 253
تقنية تخفيض المتغير........ 253
مقارنة بين تقنية تخفيض البُعدية وتقنية تخفيض المتغير........ 254
استنتاجات........ 254
المراجع 255
الملحق 256

11 توقع تخمينات الائتمان بهجين من GA-MLP 259

ملخص 259
مقدمة 259
دوافع الدراسة........ 260
بنية الفصل........ 261

تخمين الصكوك 261
عملية تخمين الصكوك 261
تخمين 262
توقع تخمين الصكوك 263
الخوارزمية الوراثية 264
تطبيق GA 265
دمج منهجيات GA وMLP 266
المنهجية 268
مجموعة المعطيات 268
اختيار متغيرات الدخل 269
بناء نموذج GA/MLP 270
النتائج والمناقشة 272
استنتاجات 275
العمل المستقبلي 275
المراجع 277

القسم السادس: تطبيقات أخرى 283

12 الموسيقى والشبكات العصبونية 283

ملخص 283
مقدمة 283
الموسيقي والذكاء الصنعي (AI) 285
الموسيقى وANNs 287
المادة المنشورة الباكرة على الموسيقى وANNs 288
المادة المنشورة الحالية على الموسيقى وANNs 291
ANNs والتأليف الموسيقي 291
ANNs وتحليل الموسيقى 295
ANNs من أجل تمييز نوع الموسيقى والأسلوب الموسيقي 297
القضايا الخاصة حول الموسيقى وANNs 298
التطبيقات الأخرى 303
خرائط التنظيم الذاتي (SOMs) 303
الشبكات العصبونية المعيارية 303

الاستنتاجات 307
ملاحظة نهائية 307
المراجع 309

13 الأنظمة الاتصالية للتنبؤ بصيد السمك 313

ملخص 313
مقدمة 313
المشكلة 313
الأهداف 315
خلفية 317
مصادر المعطيات 317
الشبكات العصبونية 318
الشبكات التابعية 320
ANFIS 321
نتائج التقنيات المطبقة 322
تدريب شبكات الانتشار الخلفي والتابع الأساسي الشعاعي 322
شبكات الانتشار الخلفي 323
شبكات RBF 325
نتائج الشبكات التابعية 327
ANFIS 330
نتائج الخوارزمية: مناقشة 334
توليد خرائط احتمال صيد السمك 338
استنتاجات 342
المراجع 344

14 طريقة الشبكات العصبونية لتحقيق الحد الأدنى للكلفة في وضع جدول الإنتاج 347

ملخص 347
مقدمة 348
مراجعة المادة المنشورة والخلفية 350

طرق تقدير الكلفة 350
ABC 351
أهمية الدراسة 352
المنهجية 352
الشبكة العصبونية MLP 352
وضع جدول الإنتاج 353
الآلية المقترحة 355
التجارب 356
NNCTE و NNTCE 356
الاختبارات الإحصائية 358
تعليقات ختامية 360
المراجع 361

15 كشف التدخل باستخدام التقنيات الحديثة: تكامل الخوارزميات الوراثية والمجموعات الخشنة مع الشبكات العصبونية 365
ملخص 365
مقدمة 365
المادة المنشورة 367
التعلّم المعتمد على GA 371
IDS المعتمد على الطريقة الهجينة 372
النتائج 374
المجموعات الخشنة للتنقيب في المعطيات 375
جدول المعطيات 376
تقريب 377
التبعية والمُختَفضات 377
قواعد القرار 377
طريقة المجموعات الخشنة من أجل IDS 378
المعطيات والمعالجة الأولية 378
إيجاد المُختَفضات 378
تخفيض القاعدة 378
إثبات الصلاحية 379

الطريقة العصبونية - الخشنة من أجل IDS 379
النتائج والمناقشة 380
الاستنتاج والبحث المستقبلي 380
المراجع 383

16 تقنيات الذكاء الصنعي التعاونية لتصنيف الأطياف النجمية: استراتيجة هجينة 385

ملخص 385
مقدمة 385
المعطيات الفلكية 389
التحليل التكويني 389
تقنيات التصنيف 391
النظم الخبيرة 392
الشبكات العصبونية الصنعية 394
تقنيات العنقدة 396
النتائج 396
الاستراتيجية الهجينة 397
الاستنتاج 399
المراجع 400

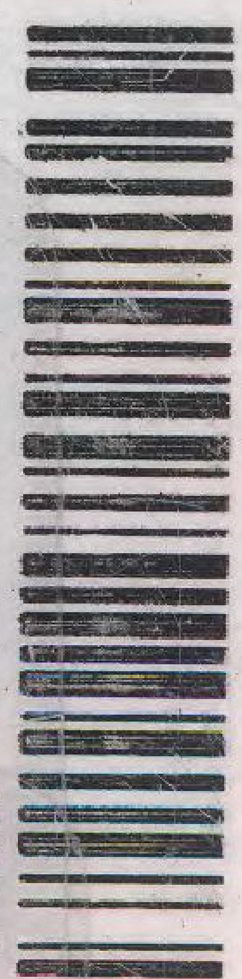
مسرد بالكلمات الصعبة 403

جدول المحتويات 418

Artificial Neural Networks by Applications

يعرض هذا الكتاب نظرة على الأبحاث الحديثة في مجال الشبكات العصبونية الصنعية. وهو يتضمن التطورات النظرية لعلم الشبكات العصبونية الصنعية وتطبيقاتها باستخدام الخصائص الذكية من أجل: التكيّفية، والتعلم الذاتي، والتصنيف، والتنبؤ، وحتى من أجل الخلق والإبداع الفني.

إن هذا الكتاب هو خلاصة التطورات الأخيرة في مجال الشبكات العصبونية الصنعية من منظور عملي فهو يعرض دراسات للتطبيقات في تنبؤ السلاسل الزمنية، واستخلاص المعرفة والهندسة المدنية، والاقتصاد، والإبداع الفني (الموسيقى)، وتحقيق الحد الأدنى للكلفة، وكشف التدخل، وتطبيقات أخرى عديدة، مما يجعله مصدراً مهماً جداً للأفكار والمعارف للباحث والمطور.



 مبتدئ
 متوسط
 متقدم
 خبير



RAY PUBLISHING & SCIENCE
http://www.raypub.com

